

道路政策の質の向上に資する技術研究開発  
成 果 報 告 レ ポ ー ト  
N o . 30-1

研究テーマ

AI 技術に基づく短期交通予測手法と  
総合的な交通需要マネジメントの研究開発

研究代表者： 広島大学准教授 力石 真  
共同研究者： 東京大学助教 浦田 淳司  
理化学研究所ユニットリーダー 美添 一樹  
熊本大学准教授 円山 琢也  
立命館大学准教授 塩見 康博  
広島大学研究員 Varun Varghese  
株式会社豊田中央研究所プロジェクトマネージャー 早川 敬一郎

令和 3 年 6 月

新道路技術会議

# 目次

研究概要	1
第1章 はじめに	3
1.1 研究の背景	3
1.2 研究の目的	3
1.3 研究の意義	3
1.4 研究体制	4
1.5 本報告書の構成	4
第2章 AI技術に基づく短期予測手法	5
2.1 はじめに	5
2.2 包括的レビューとメタ解析	5
2.3 機械学習手法を用いた交通状態の短期予測	8
2.4 転移学習による災害時交通状態の予測	12
2.5 OD交通量の短期予測: 深層学習	15
2.6 OD交通量の短期予測: entropy tucker model	17
第3章 新たな観測・介入ツールの開発と交通需要マネジメントへの適用	23
3.1 はじめに	23
3.2 Real-time context-aware 表明選好(SP)調査手法の提案	23
3.3 Real-time context-aware 表明選好(SP)調査手法を用いた混雑課金の実証分析	27
3.4 インセンティブ生成アルゴリズムの提案	31
3.5 インセンティブ及びレコメンデーションに着目した介入実験	33
3.6 ICTが生活・交通行動に及ぼす影響を包括的に捉える調査の設計・実施	36
3.7 マルチサービス交通プラットフォームが外食行動に与える影響に関する実証分析	39
第4章 供給マネジメントへの拡張	43
4.1 はじめに	43
4.2 配車サービスと公共交通の競合可能性	43
4.3 配車サービスの都市施設分布への影響評価	46
第5章 災害時の交通マネジメントへの拡張	48
5.1 はじめに	48
5.2 道路交通ネットワークの脆弱性評価	48
5.3 災害時の交通行動を捉えるためのSP調査設計	49
第6章 総合的な交通需給マネジメントに向けたICTアーキテクチャの検討	52
6.1 ICTが交通行動に及ぼす影響の包括的レビュー	52

6.2 次世代型 ICT アーキテクチャの試案.....	53
第7章 研究成果のまとめと今後の課題.....	56

**「道路政策の質の向上に資する技術研究開発」(平成 30 年度採択)  
研究概要**

番号	研究課題名	研究代表者
No.30-1	AI 技術に基づく短期交通予測手法と総合的な交通需要マネジメントの研究開発	広島大学 准教授 力石 真

多様な交通サービス供給主体が協調する交通市場を実現するため、短期需要予測手法、および、総合的な交通需要マネジメント手法の開発を研究目的として、AI 技術に基づく短期予測手法の開発、新たな観測・介入ツールの開発と交通需要マネジメントへの適用、総合的な交通需給マネジメントに向けた次世代の ICT アーキテクチャの検討を実施する研究開発。

### 1. 研究の背景・目的

円滑なモビリティ確保のために、Information and Communications Technology (ICT) や Artificial Intelligence (AI) 等を活用した交通マネジメントの強化が求められている。こうした革新技術を活用した交通マネジメントを実践に落とし込むには、多様な交通サービス提供主体が協調する交通市場を念頭に、動的プライシングやカーシェアリング、モーダルミックスを含めた種々の交通需要マネジメント施策の影響を統一的に評価するためのシステム構築が必要である。本研究では、こういった交通需要マネジメントにおいて鍵となる短期需要予測手法の開発、および、短期需要予測手法を活用した総合的な交通需要マネジメント手法の開発を行うことを目的とする。

### 2. 研究内容

以上の目的を達成するため、(1) AI 技術に基づく短期予測手法の開発、(2) 新たな観測・介入ツールの開発と交通需要マネジメントへの適用、(3) (1)及び(2)の成果を踏まえ、供給サイドのマネジメントへの拡張可能性、災害時の交通マネジメントへの拡張可能性について検討した上で、総合的な交通需給マネジメントに向けた次世代の ICT アーキテクチャの検討を行った。

### 3. 研究成果

#### (1) AI 技術に基づく短期予測手法の開発

##### (1-1) 機械学習手法を用いた交通事象の短期予測に関する包括的レビューとメタ解析

既往研究交通分野における機械学習手法の短期予測適用例を網羅的にレビューし、短期予測モデルの種類、データサイズ、予測期間等が予測精度に与える影響をメタ解析により明らかにした。

##### (1-2) 機械学習手法を用いた交通状態の短期予測

機械学習手法による交通状態の予測可能性について検討を加えた結果、(1) 機械学習手法により災害時の交通状態も一定精度の予測が可能、(2) 決定木型のモデルは精度は高いが、交通理論と整合的な解釈が難しいこと等を明らかにした。

##### (1-3) 機械学習手法を用いた OD 交通量の短期予測

OD 交通量の短期予測を行うモデルとして、深層学習を適用し精度検証を行った。また、機械学習手法と交通モデルを統合した Entropy Tucker モデルを新たに開発、その有効性を明らかにした。

##### (1-4) 転移学習による災害時交通状態の予測

災害前のデータを用いて構築したモデルを、災害後に得られたデータを用いて更新する転移学習モデルを開発し、その有効性を明らかにした。

#### (2) 新たな観測・介入ツールの開発と交通需要マネジメントへの適用

##### (2-1) Real-time context-aware 表明選好 (SP) 調査手法の提案と混雑課金への適用

リアルタイムに政策への選好情報を尋ねる real-time context-aware 表明選好 (SP) 調査手法を開発した。実証分析を通じ、選好をリアルタイムかつ文脈の影響を考慮した形で尋ねることの重要性を確認した。また、混雑課金の影響を評価した結果、自動車から他の手段への転換可能性は、トリップの出発地が都心部の場合のみ高いこと等を明らかにした。

## (2-2) インセンティブ生成アルゴリズムの提案と介入実験の実施

パーソナライズされたインセンティブを生成するアルゴリズムを開発した。また、介入実験を通じ、その導入効果を検証した。

## (2-3) マルチサービス交通プラットフォームが交通行動に及ぼす影響

Gojek や Grab といったマルチサービス交通プラットフォーム(MSTPs)が生活・交通行動に及ぼす影響を、ジャカルタ市を対象に実証的に検証し、人々は現在地から遠い場所にあるオンラインフード配達サービスを利用しない傾向にあること等を明らかにした。

## (3) 総合的な交通需給マネジメントに向けた次世代の ICT アーキテクチャの検討

MSTPs と公共交通の競合／協調関係、MSTPs が土地利用に及ぼす影響について検証し、需要だけでなく供給のマネジメントも統合した「交通受給マネジメント」への拡張が重要であることを示した。また、災害時に利用できるマネジメントツールとするため、災害時の出発時刻選択を尋ねる新たな表明選好調査の設計手法を提案した。以上の検討、及び、ICT の交通システムへの影響に関する包括的なレビューを踏まえ、ICT と交通の関係性を包括的に捉える概念モデルを構築するとともに (図 1)、次世代型 ICT アーキテクチャの要件を整理した。

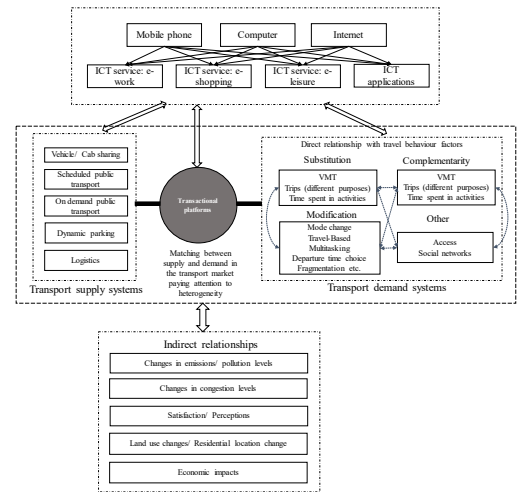


図 1. ICT-交通の包括的影響（概念モデル）

## 4. 主な発表論文

1. Chikaraishi, M., Garg, P., Varghese, V., Yoshizoe, K., Urata, J., Shiomi, Y., Watanabe, R. (2020) On the possibility of short-term traffic prediction during disaster with machine learning approaches: An exploratory analysis, *Transport Policy*, 98, 91-104.
2. Varghese, V., Chikaraishi, M., Urata, J. (2020) Deep Learning in Transport Studies: A Meta-Analysis on the Prediction Accuracy, *Journal of Big Data Analytics in Transportation*, Vol. 2, 199-220.
3. 力石真, 浦田淳司, 吉野大介, 藤原章正 (2019) 交通ネットワーク被災時の発生・集中・内々交通量及び旅行時間の変動特性, *土木学会論文集 B1*, 75 巻 1 号, 214-230.
4. Safira, M., Varghese, V., Chikaraishi, M., Gershenfeld, S., Zhao, F. (2021) Toward a Comprehensive Understanding of ICT Impacts on Activity-Travel Behavior: Preliminary Results from a Two-week Smartphone-based Survey in Jakarta, Indonesia, Accepted for 2021 EASTS conference.
5. Varghese, V., Chikaraishi, M. (2021) Personalized Incentive Design for Travel Behavior Modification: Preliminary Results from a Novel Experiment in Hiroshima, Accepted for 2021 EASTS conference.

## 5. 今後の展望

本研究の成果を踏まえると、特定の目的、特定の技術を所与とした交通マネジメントツールを開発するのではなく、実施した介入効果を随時観測し改善を繰り返していく「適応的分散処置」の発想で交通マネジメントの枠組みを構築することが望ましいと考えられる。「適応的分散処置」を機能させるためには、API 連携可能なフレキシブルなアーキテクチャを採用した交通マネジメントツールの開発・公開を進め、実験的な交通マネジメントを実施する敷居を下げ、各地で試行的な取り組みが容易に行える環境整備が肝要と考える。試行的な取り組みの成果を集めて相互にシェアし集合的学習を促進する枠組みの構築、その効果を計測するための手法の開発等が今後の研究課題として挙げられる。

## 6. 道路政策の質の向上への寄与

災害が頻発する我が国においては、公的主体が積極的に交通需給マネジメントアプリ開発に関与する意義は非常に大きいと考える。マネジメントに利用できるアプリを災害時の交通需給マネジメント体系の中に位置付けることで、災害時の効率的な交通マネジメントが可能になるとともに、例えば「災害時交通マネジメント検討会」等の場で、次の災害の備えを検討するための貴重なデータ源として活用できる。また、開発したプラットフォームを各企業に開放し API 連携できるようにすることで、多様な交通サービス供給主体が協調する交通市場の実現にも寄与するものと考えられる。

## 7. ホームページ等：無

# 第1章 はじめに

## 1.1 研究の背景

より良いモビリティサービスを確保するために、Information and Communications Technology (ICT) や Artificial Intelligence (AI) 等を活用した交通マネジメントの強化が求められている。こうした革新技術を活用した交通マネジメントを実践に落とし込むには、多様な交通サービス提供主体が協調する交通市場を念頭に、動的プライシングやカーシェアリング、モーダルミックスを含めた種々の交通需要マネジメント施策の影響を統一的に評価するためのシステム構築が必要である。また、平成30年7月豪雨災害に伴う広島市・呉市・東広島市における交通ネットワークの被害、及び、その際の交通需要マネジメントの必要性を鑑みると、民間企業に限らず公共の立場からも積極的にICTやAIの活用を進めていく必要性は極めて高い。

革新技術を積極的に取り入れた交通マネジメントを展開するためには、(1) 交通状態や交通需要の短期予測、リアルタイムでの選好情報の抽出といった「要素技術」の見通しの良い整理と、(2) 要素技術をシステムに組み上げる際のアーキテクチャの要件整理が重要と考えられる。加えて、こういった新たな交通マネジメントツールの構築は、オンライン配車サービスといった新たな交通サービスが急速に広まりつつある社会における適切な規制の在り方や、混雑課金をはじめとした種々の政策オプションの影響を統一的に議論するためのプラットフォームとしても機能することが期待される。

## 1.2 研究の目的

以上の背景を踏まえ、本研究は、以下の3つの研究テーマに取り組んだ。

- **AI技術に基づく短期予測手法の開発**：交通分野における機械学習手法適用事例の網羅的レビュー、及び、種々のパッシブデータを活用した平時及び災害時の交通状態/OD交通量の短期予測手法の開発。
- **新たな観測・介入ツールの開発と交通需要マネジメントへの適用**：Real-time context-aware 表明選好(SP)調査手法やインセンティブ生成アルゴリズムといった要素技術の開発、及び、これらの

要素技術を用いた調査、介入実験の実施。

- **総合的な交通需給マネジメントに向けた次世代のICTアーキテクチャの検討**：供給マネジメント、及び、災害時の交通マネジメントへの拡張についての追加の検討、ICTと交通行動・行動システムの関係性に関する既往研究の網羅的レビューと、それに基づく次世代型ICTアーキテクチャの要件整理。

なお、3つ目の研究テーマにある「災害時の交通マネジメントへの拡張」については、本研究プロジェクト開始直後に平成30年7月豪雨災害が発生したため、当初想定していた平時の交通需要マネジメントだけでなく、災害時の交通需要マネジメントにも対応できるよう研究対象を拡げることとした。

## 1.3 研究の意義

### (1) 研究の学術的価値

本研究の主な学術的価値は以下の3点である。

第一に、ETC2.0データ、車両感知器データ、モバイル空間統計データ、公共交通ICカードデータなどの既存のパッシブデータを最大限活用するために、既存の事例を網羅的に整理するとともに、平成30年7月豪雨災害を対象とした事例分析を通じ、その適用先を災害時の交通マネジメントにまで拡張した点が挙げられる。加えて、交通分野において広がりつつある機械学習手法の適用について、その限界についても整理している。

第二に、短期予測手法に加え、リアルタイム選好情報の抽出、インセンティブ生成アルゴリズムといった、革新技術を活かした交通需要マネジメントを実践する上で必要となる予測手法以外の要素技術を構築した。これらの提案手法の有効性を、介入実験を通じて検証したことの学術的価値は高い。

第三に、複数のサービス供給主体が競合/協調する条件を、理論モデルを用いて整理するとともに、新たな配車サービスの導入が都市構造（施設立地）に及ぼす影響について実証的なエビデンスを提示した点に大きな学術的価値があると考えられる。

### (2) 研究の実践的価値

本研究の主な実践的価値は以下の2点である。

- 本研究において開発した種々の要素技術を実

践に移す際のICTアーキテクチャに求められる要件を整理することで、学術色の強い要素技術の開発と実践の場のつながりを見通しの良いものにした。

- ▶ 平成30年7月豪雨直後に立ち上がった「広島・呉・東広島都市圏災害時交通マネジメント検討会」等の場において研究成果を適宜フィードバックし、短期予測や選好情報の抽出を実装することの実践上の意義を明らかにした。

## 1.4 研究体制

我が国の交通工学・交通計画の若手～中堅研究者に、計算機科学の研究者を加えた7名からなる研究体制をとった(図-1.1)。また、適宜、国土交通省道路局(特に地域道路経済戦略研究会)や、中国地方整備局(特に広島・呉・東広島都市圏災害時交通マネジメント検討会)、広島県警や災害時公共交通情報提供研究会(呉工業高等専門学校・神田教授主催)等と意見交換をしながら研究を進めた。また、調査や介入実験の実施についてはコンサルタントに一部業務を発注した。

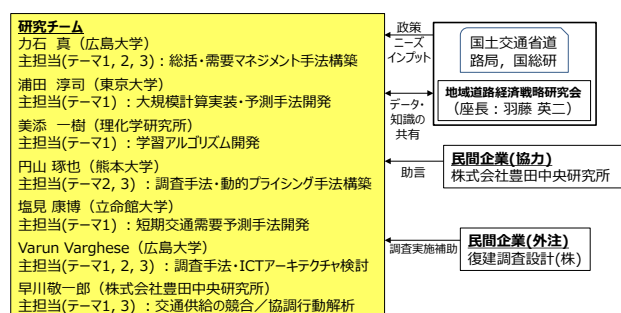


図-1.1 研究体制

## 1.5 本報告書の構成

本報告書は7章で構成されている。第1章では研究の背景、目的、意義及び研究体制について述べた。

第2章では、種々のAI技術に基づく短期予測手法を開発する。具体的には、交通分野における機械学習手法の短期予測適用例を網羅的にレビューし、学術雑誌にて公表されている結果を整理したデータベースを作成、メタ解析を実施し、対象とする交通事象や使用するデータと解析手法の選択の関係を定量的に明らかにする。次に、車両感知器データやETC2.0データ、モバイル空間統計、公共交通ICカードデータ等のパッシブデータを利用し、平時及び災害時の交通状態/OD交通量の短期予測を行う一連の手法を整理し、その精度を実証的に検証した。さらに、交通理論が提供する交通現象の明快な解釈と、機械学習手法が提供する予測精度の大幅な向上の双方のメリットを享受するハイブリッド型の短期予測手法についても開発した。

第3章では、新たな観測・介入ツールを開発し、交通需要マネジメントへの適用を念頭に置いた介入実

験結果について報告する。まず、顕示選好(RP)行動結果をもとにリアルタイムで政策に対する選好情報を尋ねるreal-time context-aware 表明選好(SP)調査手法を開発し、混雑課金の影響評価に適用する。次に、個人個人の時間価値の異質性を手掛かりに、パーソナライズされたインセンティブを生成するためのアルゴリズムを開発し、生成したインセンティブが付与される状況(行動結果に応じて謝金額を増減させることで対応)下及びレコメンデーション情報提供下における交通行動を観測・評価する介入実験について報告する。その後、GojekやGrabといったマルチサービス交通プラットフォーム(MSTPs)が生活・交通行動に及ぼす影響を確認することを目的に、インドネシア・ジャカルタ市を対象としたプローブパーソン(PP)-表明選好(SP)調査を設計・開発し、特にオンラインフード配達サービスの影響評価に焦点を当てた分析結果について報告する。

第4章では、供給側のマネジメントの必要性について検討を加える。まず、1次元都市モデルと確定的交通機関選択モデルを用いて、配車サービスと従前の公共交通機関の関係が協調もしくは競合となるような条件を明らかにする研究成果について報告する。次に、オンラインフード配達サービスが施設分布に及ぼす影響を実証的に確認した分析結果について報告する。

第5章では、交通需給マネジメントの災害時への拡張を念頭に、交通網の脆弱性評価、災害時における選好情報の抽出方法について検討を加える。具体的には、まず、全国69都市の交通網の脆弱性評価を行った結果を報告する。次に、災害時における選好情報の抽出を行うためのSP調査の設計について検討する。

第6章では、開発した種々の要素技術を活用した総合的な交通需給マネジメント実践のためのICTアーキテクチャを検討する。

第7章で研究成果全体をまとめ、今後の課題・展望を整理する。

## 第2章 AI技術に基づく短期予測手法

### 2.1 はじめに

本章では、AI技術に基づく短期予測手法について整理する。2.2節では、深層学習の交通分野への適用事例を包括的にレビューし、メタ解析を通じて予測精度に寄与する要因を定量的に把握する。2.3節では、7種類の交通状態短期予測モデルを構築し、平時/災害時双方の状況下におけるモデルのパフォーマンスを比較検証する。2.4節では、災害時における予測精度の改善を図るため、転移学習を用いた実証分析を実施する。2.5節、2.6節では、機械学習手法を用いたOD交通量の短期予測の実証分析を行う。2.3節及び2.6節では、上記に加えて、機械学習手法と交通理論との整合性についても議論を加える。

### 2.2 包括的レビューとメタ解析

#### (1) 論文対象とデータベースの整備

短期予測手法の開発に先立ち、交通解析に適した深層学習アルゴリズムを整理することを目的に、交通の機械学習手法を用いた短期予測適用事例の包括的な整理を行った。また、レビューした計136本の論文から2,314の適用事例を整理したデータベースを構築し、予測精度に寄与するモデル構造や要因を把握することを目的としたメタ解析を行った。データベースは、SCI-EXPANDED, SSCI, A&HCI, ESCI 雑誌に限定し、Web of Science上において表-2.1に示すキーワードで論文を検索し、表-2.2に示す変数を整理した。なお、紙面の都合上、詳細及び文献のリストについてはVarghese et al. (2020)<sup>4)</sup>を参照されたい。

#### (2) レビュー結果概要

以下では、レビュー結果の概要を述べる。

表-2.3に分析対象別/出版年別論文数を示す。表より、深層学習を活用した既往研究が過去5年のうちに急増していることが確認できる。また、交通流 (traffic flow) 及び交通速度 (Traffic speed) の短期予測への適用が最も多く、次に、交通需要 (Travel demand) の短期予測の事例が多い。また、渋滞を予測するための入力データとなる交通状態や交通需要の短期予測ではなく、交通渋滞を直接予測しようとする研究の存在も確認された。

表-2.4にデータ種類別論文数を示す。図より、車両感知器 (loop detector) データを利用した研究が最も多く、GPSデータ、CCTVデータを用いた事例研究が続くことが確認できる。加えて、スマートフォンのアプリから取得したデータを利用した研究事例も蓄積されつつあり、既に多様なデータを活用した事例が蓄積されつつあることが確認できる。

表-2.5に対象国別/対象地域別論文数を示す。図より、ほとんどの事例研究は中国と米国を対象になされていることが確認できる。わが国を対象とした事例研究は表-2.1に示す検索キーワードに基づくわずか2例に限られる。対象地域については、都市部、地方部ともに一定の研究蓄積があることが確認できる。

表-2.6に精度指標別論文数を示す。表より、論文によって採用される精度指標が異なることが確認できる。これらの精度指標の選択は、当然のことながら離散量を目的変数とするか、連続量を目的変数とするかにも依存するが、同じ目的変数であっても比較の困難な精度指標を使用しているケースも散見された。

表-2.1 論文検索キーワード

使用したキーワード	論文数
deep learning AND traffic flow prediction	33
deep learning AND traffic speed prediction	14
deep learning AND traffic accident	9
deep learning AND travel demand	16
deep learning AND transport mode	3
deep learning AND travel behavior	1
deep learning AND driver behavior	28
deep learning AND distracted driving	3
deep learning AND travel time prediction	6
deep learning AND congestion	12
deep learning AND traffic state prediction	1
既存のレビュー論文 (Do et al., 2019 <sup>1)</sup> ; Nguyen et al., 2018 <sup>2)</sup> ; Wang et al., 2019 <sup>3)</sup> ) で引用された事例	72
整理した総論文数	198
精度指標等が不明で分析対象外とした論文数	62
最終的に分析に用いた論文数	136



表-2.7にモデル種類別／分析対象別の適用事例を示す。畳み込みニューラルネットワーク（CNN）の適用が最も多いこと、長期短期記憶（LSTM）がそれに続くことが確認できる。また、CNNとRNNを統合した学習モデルの利用が進みつつあること、交通状態予測や需要予測においてはLSTM等の時間情報の取り扱いに長けたモデルが、交通事故や運転挙動の予測についてはCNNをはじめとした空間情報の取り扱いに長けたモデルが用いられる傾向にあることが確認できる。

表-2.2 論文から抽出した変数

変数	説明
Year	出版年
Coverage	対象国
Region	対象地域（都市部／地方部）
Data type	データの種類
Target	分析対象
Sample size	学習用、検証用、テスト用データの標本数
Time of prediction	何分先の予測を行ったか
Method	使用したモデルの種類
Accuracy	予測精度

表-2.3 分析対象別／出版年別論文数

	2014	2015	2016	2017	2018	2019	Total
Accidents	0	0	1	2	4	5	12
Congestion	0	1	1	3	4	2	11
Driver Behavior (DB)	0	0	1	0	4	12	17
Mode and activity choice (M-AC)	0	0	0	1	3	1	5
Travel demand (TD)	0	0	1	6	3	9	19
Travel time prediction (TTP)	0	0	2	0	1	4	7
TTP and Distance (Dist.)	0	0	0	1	0	0	1
Traffic Flow	2	2	5	6	7	17	39
Traffic speed	0	1	2	7	4	9	23
Speed; Flow and Occupancy (Occ)	0	0	0	1	0	0	1
Speed and Flow	0	0	0	1	0	1	2
Total	2	4	13	28	30	59	136

表-2.4 データ種類別論文数

データの種類	論文数
Global positioning system (GPS)	38
Loop Detectors	55
Accelerometer, magnetic, gyroscope, barometer sensors (AMGB)	5
Closed circuit television (CCTV) cameras	22
Applications	10
Accident data	9
Automated fare collection (AFC)	8
Intelligent transport systems (ITS)	5
Others	4
Secondary sources	40

表-2.5 対象国別／対象地域別論文数

対象国	論文数
不明	10
Australia	1
Brazil	1
China	53
Canada	1
Denmark	1
Egypt	1
Germany	1
Greece	1
Hong Kong	1
India	2
Japan	2
Malaysia	1
Morocco	1
Netherlands	2
Norway	1
Palestine	1
Poland	1
South Korea	4
Taiwan	1
Uganda	1
United Kingdom (UK)	11
United States of America (USA)	45
対象地域	論文数
不明	13
都市部	75
地方部	48

表-2.6 精度指標別論文数

精度指標	論文数	定義
Accuracy	29	$= \frac{\text{Number of correct predictions}}{\text{Total number of predictions}}$
AUC	3	Area under curve between recall (true positive rate, y-axis) and false positive rate (x-axis)
Precision	2	$= \frac{\text{True positive}}{\text{True positive} + \text{False positive}}$
Error rate	1	$= \frac{\text{Number of incorrect predictions}}{\text{Total number of predictions}}$
MAPE	56	$= 100 \times \frac{1}{N} \sum_{i=1}^N \frac{ \hat{y}_i - y_i }{y_i}$
MAPE@10	1	MAPE in the samples with demand intensity greater or equal to 10 (top 4.45% of the largest samples)
MAPE@5%	1	MAPE with top 5% highest value samples
sMAPE	2	$= 100 \times \frac{1}{N} \sum_{i=1}^N \frac{ \hat{y}_i - y_i }{y_i + \hat{y}_i + c}$
MRE	25	$= \frac{1}{N} \sum_{i=1}^N \frac{ \hat{y}_i - y_i }{y_i}$
Average accuracy	5	$= 100 - \text{MAPE} \text{ or } 1 - \text{MRE}$
R <sup>2</sup>	1	Proportion of the variance in the estimated values that is predictable from the observed values
Recall	5	$= \frac{\text{True positive}}{\text{True positive} + \text{False negative}}$
RMSE%	3	$= 100 \times \frac{\sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2}}{\bar{y}}$
RMSEP%	1	RMSE% with 70% critical road sections
Average error rate	1	Percentage error (no specific mention of formula or type)

表-2.7 モデル種類別／分析対象別適応事例数

	Accidents	Congestion	DB	M-AC	TD	TTP	Distance	Flow	Speed	Occupancy	Total
CNN	36	23	38	4	20	10	0	43	101	3	278
CNN-GRU	0	0	2	0	0	0	0	9	18	0	29
CNN-LSTM	3	2	2	0	9	3	0	11	18	0	48
CNN-RNN	0	0	0	0	0	0	0	0	10	0	10
LSTM-GRU	0	0	0	0	0	0	0	0	1	0	1
DBN	2	2	5	0	0	44	0	50	10	1	114
DNN	16	1	5	2	10	2	2	38	37	0	113
GRU	0	8	0	0	3	2	0	2	33	0	48
LSTM	10	16	12	4	69	11	0	77	90	0	289
RNN	1	9	12	1	1	4	0	12	20	0	60
SAE	4	1	0	0	14	20	0	151	32	0	222
TM	59	27	46	19	90	35	1	324	218	1	820
SNN	7	14	7	1	42	6	0	142	62	1	282
Total	138	103	129	31	258	137	3	859	650	6	2314

注: traditional method (TM); shallow neural network (SNN); deep neural networks (DNN); stacked auto-encoders (SAE); deep belief networks (DBN); classical recurrent neural networks (RNN); long short-term memory (LSTM); gated recurrent unit (GRU); convolutional neural networks (CNN)

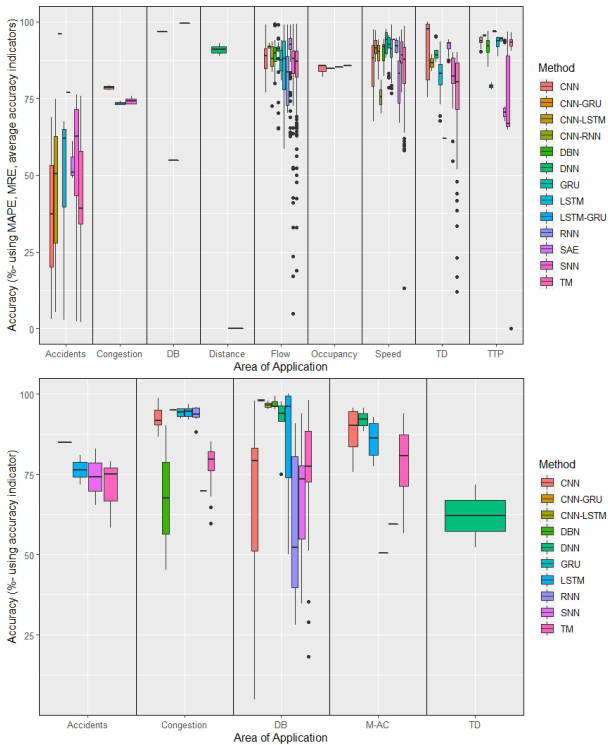


図-2.1 予測精度の箱ひげ図

図-2.1に予測精度の箱ひげ図を示す。図より、推定精度は分析対象によって大きく異なることが確認できる。特に、交通事故の予測において精度が低下する傾向にあることが確認できる。一方、交通流や旅行速度の予測の精度は比較的高くなる傾向にあることも確認された。

### (3) メタ解析結果

表-2.8に、目的変数に予測精度 (%) をとったマルチレベル回帰モデルの推定結果を示す。論文固有の非観測要因の影響を除去する目的から、正規分布に従う論文レベルのランダム項を導入している。まず、

モデルの種類を表す6つのダミー変数 (DNN, SAE, DBN, CNN, LSTM, CNN-LSTM) のパラメータ推定値を確認すると、深層学習の利用により予測精度が平均3~5.5%程度改善することが確認できる。特に時間依存性、空間依存性双方の特徴を捉えることに長けたCNN-LSTMを利用した際に予測精度が最も改善することが示された(平均5.5%程度の改善)。また、分析対象については、旅行速度の予測精度が最も高く、交通流がそれに続くことが確認された。交通事故や運転挙動については、パラメータ値がそれぞれ-15.51, -13.88と、平均約15%, 他の分析対象よりも予測精度が低いことも併せて確認できた。データの種類としては、CCTVや二次的な情報源を用いた場合に推定精度が高くなる一方、GPSや車両感知器データを利用した場合、推定精度が低くなる傾向にあることが示された。ただし、この結果はデータ固有の観測誤差と、分析対象の予測困難性に起因する誤差の双方を含む点に注意が必要である。また、都市部を対象とした研究においては予測精度が平均約3%低下することも併せて確認された。

表-2.8 メタ分析結果

Models	Estimate	t value
<i>Fixed effects</i>		
(Intercept)	83.95	21.88
<u>Methodologies</u>		
TM	-1.72	-3.11
DNN	3.95	3.5
SAE	3.09	3.93
DBN	4.06	3.18
CNN	3.8	4.84
LSTM	5.07	6.7
CNN-LSTM	5.52	3.86
<u>Area of application</u>		
Speed	8.47	2.87
Flow	2.83	0.94
Travel demand	-8.46	-1.84
Driver behaviour	-13.88	-2.68
TTP	2.1	0.45
Accident	-15.51	-2.94
<u>Source of data</u>		
GPS	-8.28	-2.55
Loop detector	-2.47	-0.73
CCTV	3.34	0.82
Secondary source	4.74	2.91
<u>Target area</u>		
Urban	-3.23	-3.66
<i>Random effects (variance)</i>		
Study	189.53	
Residual	68.77	
<i>Model performance parameters</i>		
Sample size (cases)	2314	
Sample size (study)	136	
AIC	16781.89	
Log Likelihood	-8369.94	
R square (only with fixed effects)	0.175	
R square (with fixed and random effects)	0.78	

表-2.9 メタ分析結果 (traffic flow及びspeedのみ)

	Estimate	t value
Intercept	85.06	29.17
<b>Methodologies</b>		
TM	-1.58	-3.54
DNN	1.99	2.45
SAE	1.72	2.49
DBN	2.97	2.98
CNN	3.38	5.21
LSTM	2.98	4.89
CNN-LSTM	4.5	3.59
Loop detector	3.66	3.76
Sample size (1E-8)	5.9	2.46
Time horizon of prediction (min.) (1E-2)	-5.28	-8.03
<b>Random effects (variance)</b>		
Study	244.25	
Residual	22.76	
<b>Model performance parameters</b>		
Sample size (cases)	991	
Sample size (study)	36	
AIC	6105.631	
Log Likelihood	-3039.816	
R square (only with fixed effects)	0.485	
R square (with fixed and random effects)	0.956	

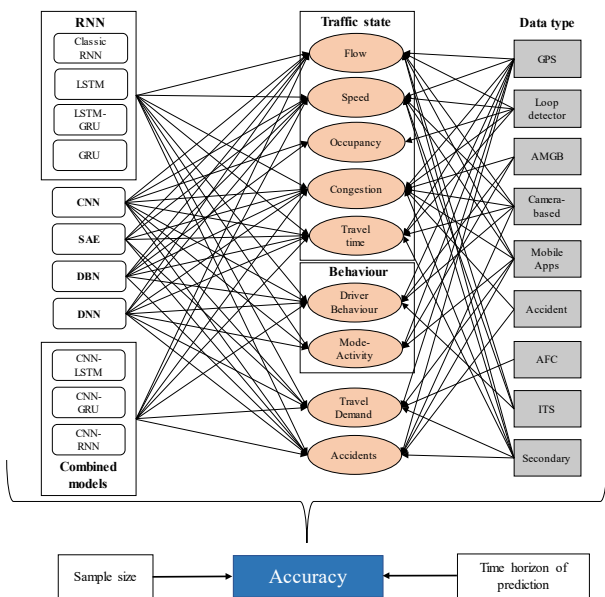


図-2.2 交通分野における深層学習の適用事例のまとめ

表-2.9に交通流と旅行速度を対象に行われた事例のみを取り出し、メタ分析を行った結果を示す。深層学習の利用による予測精度の改善は、全標本を対象に実施した表-2.8のメタ解析結果と同様の傾向を示すことが確認された。また、新たに標本数と予測スパン（何分先の予測を行うか）の変数を追加したところ、1億レコード追加する度に平均5.9%の精度改善が可能であることが示された。また、予測スパンについては、予測スパンが10分伸びる毎に平均約0.53%精度が低下することが示された。

#### (4) レビューの総括

本研究では、交通分野における深層学習手法の適用事例について包括的な文献サーベイを実施した。図-2.2に交通分野における適用事例を整理する。特に重要な点として、過去の深層学習手法の適用事例のほとんどが既存手法のナイーブな適用に留まっており、近年議論が盛んになりつつあるモデルの解釈可能性やそれを踏まえた機械学習手法の適用は極めて限られている点が指摘できる。この点については、例えばニューラルネットワーク内の一部の変数の影響を線形に限定することによって解釈可能性の担保、旅行時間節約価値等の計算が可能になるように工夫した研究が行われはじめて<sup>4)</sup>。以降の節では、交通状態、OD交通量の予測を行うとともに、交通理論と整合的な解釈可能性の高いモデル構造を持つ機械学習モデルを提案する。

#### 2.3 機械学習手法を用いた交通状態の短期予測

動的交通マネジメントを行うには、精度の高い短期予測モデルの構築が求められる。こういった短期予測モデルは、交通の需要と供給が急変する災害時にこそ求められるが、災害時を対象に実施された研究はほとんど見当たらない。そこで本研究では、平成30年7月豪雨災害時の交通状態の短期予測を行い、その精度検証を行う。また、前節で確認したように、日本での適用事例の蓄積が不足していることを鑑み、災害前の交通状態の予測可能性についても検証を加える。比較検証に用いた短期予測モデルは、ランダムフォレスト、サポートベクトルマシン、XGBoost, shallow feed-forward neural network, deep feed-forward neural networkである。なお、本節は、Chikaraishi et al. (2020)<sup>6)</sup>を要約したものであり、詳細は原著論文を参考にされたい。

##### (1) 背景・目的

平時と被災時の交通マネジメントには以下に述べるような違いがある。第一に、道路網の被災に伴い交通容量が低下する。第二に、被災者の旅行パターンの変化、及び、土砂を撤去する車両といった災害関連需要が発生するため、平時とは交通需要パターンが異なる。第三に、上記の災害に伴う交通供給と交通需要の変化は、被災後に初めて把握できるものであるため、過去に蓄積されたデータをマネジメントに直接活用できない可能性が高い。第四に、被災時は平時とは異なる目的のもと交通マネジメントを行う必要性が生じる。例えば、総旅行時間の減少よりはむしろ、土砂撤去や救援車両の通行を優先したオペレーションが必要なケースが考えられる。

的確な短期予測を行うことが動的な交通マネジメントの効率性を高めることは以前より繰り返し指摘されているものの<sup>7)</sup>、前述したような被災時の交通状況の特性により短期予測モデルの構築は容易ではない。前節のレビュー結果からも明らかのように、機

機械学習は複雑な非線形関係の交通状態を柔軟に表現できることから、短期予測の精度向上に寄与する可能性が高い。しかしながら、機械学習の被災状況への適用についてはほとんど研究蓄積がなく、その有用性は明らかとはなっていない。本研究では、以上の背景を踏まえて、交通ネットワークが不通となっている期間において、様々な機械学習モデルを用いた短期交通予測の可能性を検証する。

機械学習を適用することの利点は予測性能のみならず、災害時にどこのエリアでどのような被災があり、交通の供給・需要がどのように変化したか、といった事前情報を政策決定者が整理・理解するが必要ない点にも求められる。この点が被災時においては重要である。一方、機械学習モデルの欠点として、計算過程がブラックボックスであることが頻りに指摘されている。昨今のAIガイドラインを踏まえると、交通マネジメントシステムを実務において用いるには、モデルの説明可能性を一定程度担保しておく必要がある。そこで本研究では、機械学習モデルの結果の解釈可能性についても検証を行う。災害後、異なる場所での交通状態の依存関係は異なることが想定される。例えば、(1)災害時の交通量が過飽和状態になると下流の交通状態が上流の交通状態に与える影響が大きくなる、(2) 手作業の交通管制は、他の地点における交通状態と予測地点の依存関係の消失に寄与する、といったようなことが想定される。実証分析においては、機械学習モデルの結果から、このような変化を読み取れるか確認する。

後述するように、被災後は、共変量シフト（交通流と時間占有率がとる値の範囲が被災前後で異なる）と概念シフト（入力変数と出力変数の関係性が被災前後で異なる）が発生する可能性が極めて高く、その意味で転移学習の適用は魅力的である。しかし以下の分析では、被災後に得られたデータのみを利用してナイーブにモデルを構築することにより、共変量シフト及びコンセプトシフトの問題を扱うシンプルな手法を適用した。転移学習を利用したモデル予測精度改善については次節にて扱う。

本節の分析を通じて、以下の2つの貢献を目指す。

(1)どの機械学習モデルが交通状態の予測においてより良い精度を示すか、災害の前後で精度がどのように変化するか、(2)結果が既存の交通流理論の観点から解釈可能であるかどうか。実証分析を通じて、予測精度の高いモデルが、必ずしも交通渋滞発生メカニズムをより良く模倣するわけではないことを示す。

## (2) 対象地域と使用データ

6月末から降り始め、7月6日にピークとなった大雨は激しい土砂災害を引き起こし、広島市と呉市、東広島市の広範囲で通行止めを引き起こした。特に広島市と呉市を結ぶ国道31号線では、並行している鉄道と高速道路が不通となったため3ヶ月近く深刻な渋滞が生じた（国道31号線も被災して一時不通となったが、7月11日に復旧した。）。国道31号線沿いの地

域（小屋浦・天応）では土砂崩れによる被害が深刻であったことから、これらの地域における渋滞を軽減することが被災後求められた。そこで本研究では、国道31号線の交通状態（交通量と時間占有率）の短期予測を行う。

図-2.3に対象地域と分析に使用する車両検知器の位置を示す。主に「広島・呉・東広島都市圏災害時交通マネジメント検討会」における検討を通じ、国道31号線の以下の状況が確認された。

- (a) 広島市と呉市を結ぶJR呉線は9月9日に復旧したが、被災直後と比較して旅行時間は安定したもの（分散が小さい）、国道31号線の旅行時間は短縮されなかった（図-2.4）。
- (b) 被災前の主なボトルネックは車両検知器(LD-14)から始まるトンネルであったものの、被災後は主に復旧作業が行われた地域であった(LD-4やLD-9周辺)。

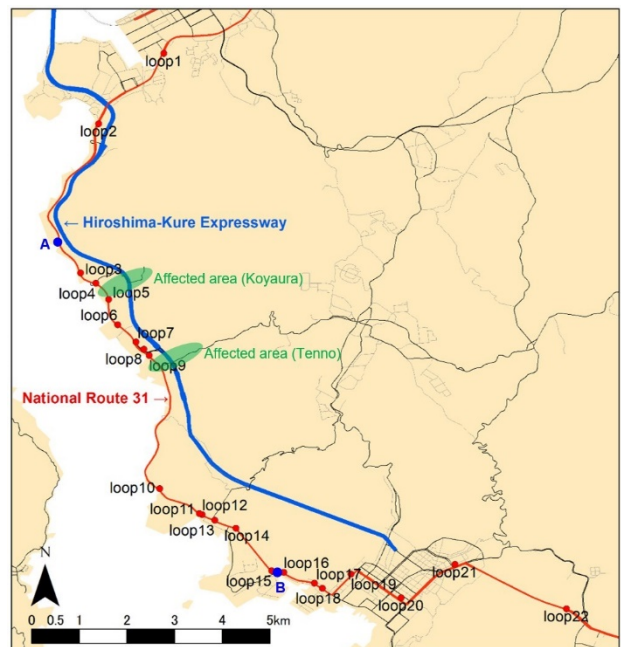


図-2.3 対象地域（国道31号）



出典：国土地理院ウェブサイト (<http://www.gsi.go.jp/BOUSAI/H30.taihuu7gou.html>)

写真-1.1 被災後の航空写真と車両感知器の位置




図-2.4 旅行時間の経時変動 (ETC2.0 データより作成)

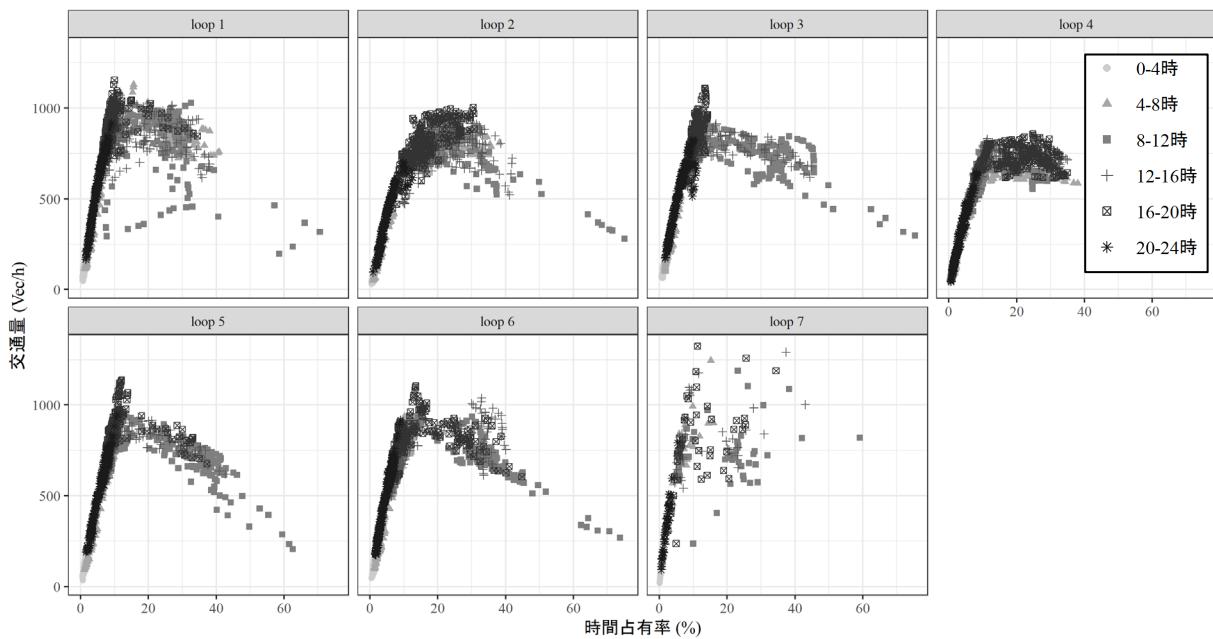


図-2.5 Loop9の時間帯別1時間交通量(台)-時間占有率(%)  
【2018年8月30日(木)】

- (c) 天応地区の災害対応拠点(呉ポートピアパーク(写真-1.1参照))と被災地間で多くの短距離トリップが発生した。この2点間を通過する車両にとっては道路容量が減少した(図-2.5)。
- (d) 天応から国道31号線にかけて深刻な渋滞が発生したため、天応地区の入口で警察による手動の交通コントロールが行われた。被災前と比べて交通流のパターンは劇的に変化した。予測モデル開発の側面から、(a)-(c)は災害の前後で共変量シフトが生じていることを示唆している。つ

まり、交通流と時間占有率の分布は被災前後で異なっている。(d)は、入力と出力の変数の関係が異なるという概念シフトが被災前後で生じていることを示している。

以下では、図-2.3に示す国道31号線の22箇所に設置された1分毎の車両感知器のデータを利用し、災害時における交通状態の短期予測、及び、結果の解釈可能性を検証する。本研究で用いるデータは2018年の7月1日から8月31日までである。

### (3) 研究方法

短期予測モデル構築においては、共変量シフト／概念シフトの問題に対応するため、以下の3つの期間にデータを分割し、各々の期間毎にモデルを作成した。

- A) 7月1日～7月5日：被災前の交通状態
- B) 7月12日～7月18日：被災直後の交通状態
- C) 8月20日～8月26日：被災後の交通状態

被災前の交通状態においては、5日間 ( $5 \times 24 \times 60 = 7200$ )個のデータがあり、そのうち最初の5000個をモデルの訓練用データ、残りを検証用データとした。一方で被災後においては、それぞれ( $7 \times 24 \times 60 = 10,080$ )個のデータがあり、最初の7000個を訓練データ、残りを検証用データとした。先述したように、LD-9とLD-18の2つの車両感知器に対して予測を行い、5分、10分、20分の3つのタイムスパンで予測した。交通流と占有率の短期予測が最重要である災害時への適用を念頭に時間範囲を選択した。

比較に用いたモデルは以下の通りである。

1. Auto Regressive Integrated Moving Average (ARIMA)
2. Vector autoregression (VAR)
3. Random Forest (RF)<sup>8)</sup>
4. Support Vector Machine (SVM)<sup>9)</sup>
5. XGBoost (XGB)<sup>10)</sup>
6. Shallow Feed-forward Neural Network (FFNN)
7. Deep Feed-forward Neural Network (DNN)

Deep Feed-Forward Neural Network (Glorot and Bengio, 2010)に基づいた深層学習モデルではトライ&エラーの結果、8層のレイヤーを採用した。

7つの機械学習モデルを用いて1)交通流(Q),2)時間占有率(K)の2つの変数を出力として予測を行った。これらのモデルを3つの期間に対して3つのタイムスパンで検証した。モデルの予測精度は、予測値と実測値間のモデルの説明力のずれを示す平均絶対誤差(MAE)、決定係数(R<sup>2</sup>)を用いて検証した。

国道31号線における22個の車両感知器から得られた交通量Qと時間占有率Kの情報が存在している。車両感知器から得られた22個のQ値、22個のK値、さらに曜日の合計45個を入力変数として用いた (ARIMA, VARを除く)。また、45個の変数を60分間にわたって用いるため、入力総計は $45 \times 60 = 2700$ 個となった。

### (4) 結果

本研究では、5分、10分、20分の3つのタイムスパンで交通流(Q)、時間占有率(K)を予測するモデルを構築する。先述したように、3つの期間(被災前、被災直後、被災後)を対象に予測精度を検証した。

表-2.10にモデルの予測精度を示す。具体的には、R<sup>2</sup>及び平均絶対誤差を示している。交通量と占有率の予測精度と比較すると、交通量の予測精度が概ね低いことが確認できる。さらに、タイムスパンが長い場合ほど予測精度が低下する傾向がある。タイムスパンの増加に伴う予測精度の低下は大きくなく、こ

の結果は、前節のメタ解析結果と整合的である。被災前期間においては、いずれのモデルにおいても精度の差はなかった。しかし、XGBとランダムフォレストは相対的に良い精度であった。R<sup>2</sup>の比較から、深層学習モデルの精度は他の機械学習モデルより相対的に低いことがわかる(表-2.10参照)。また被災後期間においては特に、ARIMAやVARといった従来のモデルと比較して機械学習モデルは一般的に良い精度で予測されることも示された。

被災直後の期間(2018年7月12日～18日)においては、すべてのタイムスパンにおいて、また交通流と時間占有率の予測において、XGBが最も優れていることが確認された。この期間には最もネットワークの通行止めの影響を受けた期間である。XGBは一部の場合(5分後と20分後のタイムスパン)において最高で94%のずれを示した。深層学習であるDNNは5分後のタイムスパンでの予測精度が良好であった。しかしその他のタイムスパンに対しては、他の機械学習手法に比べて予測精度が高いとは言えない結果であった(表3.1-1参照)。最後に、被災後期間(2018年8月20日～27日)において、ランダムフォレストとXGBが良好なモデルであることが確認された。この期間においては道路ネットワークが完全に復旧してはいたわけではなく、通行止めの影響が残っていたことに留意しなければならない。他の期間と同様に、DNNは一貫して、ランダムフォレストやXGB, SVMより精度が劣っていた。一方で、占有率の予測に対する決定係数R<sup>2</sup>においては、比較的高いことが確認された。

以上の結果から、限られたデータ量から、深層学習を用いて高い予測精度を出すことは困難であることが改めて確認された。先行研究においても、ランダムフォレストのような機械学習は、短期予測モデルにおいては深層学習モデルより性能が優れていることが報告されている。通常、深層学習モデルは短期の交通状態を推定するのに数ヶ月の情報を用いる。しかしながら、災害時においては、多くのデータを利用することができない可能性が高い。それぞれ7日間のデータを持つ期間においては、モデルにおける予測精度はXGBが最も高い。

一方、DNN及びXGBの予測精度向上に寄与している重要度の高い特徴量トップ10を取り出して比較すると(表-2.11)、DNNについては10分までの予測においては、「当該区間の交通状態は、上流側からの流入交通量、及び、下流側からの渋滞の延伸に影響を受ける」という理論的な解釈が可能な結果が概ね得られているのに対し、XGBでは、下流側の交通量に影響を受けるという、理論的に解釈が難しい結果となった。このことから、予測精度の高いモデルが、必ずしも交通渋滞発生メカニズムをより良く模倣するわけではないことが示唆された。

### (5) まとめ

以上、災害時の交通状態予測を事例として、深層学習を含む複数の機械学習手法の精度検証を行った。

比較の結果、特にXGBoostの推定精度が高いことが確認された。一方DNNは、XGBoostに比べ精度は落ちるものの、既存の交通流理論に矛盾のない結果を得られることが確認された。以上より、最も良い精度を有するモデルが渋滞の発生メカニズムをうまく模倣しているとは限らないことから、予測精度のみでモデル選択を行うことに注意する必要があることが示唆された。

表-2.10 予測精度の比較

Period	Time	5 min		10 min		20 min		
		Flow	occupancy	Flow	occupancy	Flow	occupancy	
A	ARIMA	0.86	0.87	0.81	0.81	0.74	0.72	
		(0.27)	(0.25)	(0.32)	(0.31)	(0.38)	(0.40)	
		VAR	0.80	0.83	0.73	0.75	0.66	0.63
			(0.30)	(0.27)	(0.35)	(0.33)	(0.39)	(0.38)
		RF	0.87	0.89	0.83	0.85	0.82	0.84
			(0.22)	(0.21)	(0.27)	(0.25)	(0.27)	(0.26)
	SVM	0.85	0.85	0.83	0.83	0.81	0.80	
		(0.24)	(0.24)	(0.26)	(0.26)	(0.29)	(0.29)	
	XGB	0.87	0.88	0.83	0.85	0.81	0.82	
		(0.23)	(0.22)	(0.27)	(0.25)	(0.29)	(0.28)	
	FFNN	0.74	0.75	0.66	0.74	0.75	0.71	
		(0.34)	(0.35)	(0.40)	(0.35)	(0.36)	(0.39)	
	DNN	0.83	0.85	0.80	0.79	0.74	0.77	
		(0.28)	(0.27)	(0.32)	(0.31)	(0.37)	(0.34)	
	B	ARIMA	0.77	0.91	0.68	0.84	0.60	0.75
			(0.31)	(0.20)	(0.39)	(0.27)	(0.45)	(0.34)
		VAR	0.65	0.88	0.57	0.83	0.53	0.73
			(0.45)	(0.25)	(0.50)	(0.30)	(0.51)	(0.34)
RF		0.80	0.93	0.77	0.90	0.75	0.87	
		(0.31)	(0.18)	(0.36)	(0.21)	(0.38)	(0.26)	
SVM		0.78	0.88	0.76	0.85	0.75	0.79	
		(0.35)	(0.26)	(0.37)	(0.30)	(0.39)	(0.34)	
XGB		0.82	0.94	0.79	0.91	0.82	0.94	
		(0.29)	(0.17)	(0.33)	(0.21)	(0.29)	(0.17)	
FFNN		0.72	0.86	0.72	0.83	0.70	0.76	
		(0.42)	(0.28)	(0.41)	(0.32)	(0.42)	(0.37)	
DNN		0.79	0.89	0.76	0.84	0.69	0.74	
		(0.35)	(0.26)	(0.40)	(0.31)	(0.44)	(0.39)	
C		ARIMA	0.76	0.90	0.70	0.84	0.65	0.76
			(0.34)	(0.24)	(0.41)	(0.30)	(0.45)	(0.37)
		VAR	0.67	0.82	0.61	0.76	0.30	0.45
			(0.40)	(0.27)	(0.45)	(0.31)	(0.45)	(0.36)
	RF	0.84	0.90	0.82	0.87	0.82	0.83	
		(0.25)	(0.19)	(0.29)	(0.23)	(0.30)	(0.26)	
	SVM	0.80	0.87	0.77	0.84	0.74	0.81	
		(0.31)	(0.23)	(0.35)	(0.26)	(0.38)	(0.29)	
	XGB	0.83	0.90	0.82	0.87	0.81	0.82	
		(0.27)	(0.19)	(0.29)	(0.23)	(0.31)	(0.27)	
	FFNN	0.78	0.84	0.52	0.79	0.71	0.77	
		(0.32)	(0.25)	(0.51)	(0.30)	(0.38)	(0.32)	
	DNN	0.79	0.86	0.71	0.80	0.70	0.70	
		(0.32)	(0.23)	(0.39)	(0.28)	(0.41)	(0.37)	

注: A: 7月1日~7月5日; B: 7月12日~7月18日; C: 8月20日~8月26日

表-2.11 重要度の高い特徴量トップ10 (DNN, XGB)

Method	Dependent variable	Period	Prediction horizon	Top 10 important features										
				Q9	Q9	Q5	Q4	Q3	Q2	Q2	K9	K9		
DNN	Q	July 1-5	5 min	Q9	Q9	Q5	Q4	Q3	Q2	Q2	K9	K9		
			10 min	Q9	Q3	Q2	Q1	K22	K22	K22	K21	K4		
			20 min	Q22	Q21	Q3	Q2	K22	K21	K21	K15	K7		
		July 12-18	5 min	Q9	Q9	Q9	Q9	Q9	Q8	Q5	Q3	K12	K9	
			10 min	Q9	Q9	Q9	Q5	Q3	K12	K4	K4	K2	K2	
			20 min	Q17	Q17	Q17	Q17	Q9	Q9	Q5	K16	K10	K2	
		August 20-26	5 min	Q9	Q9	Q9	Q9	Q9	Q9	Q9	Q7	Q4	Q3	
			10 min	Q9	Q9	Q9	Q9	Q9	Q9	Q3	K17	K17	K3	
			20 min	Q19	Q19	Q19	Q13	Q9	Q9	Q9	Q7	Q3	Q3	
		XGB	Q	July 1-5	5 min	Q9	Q9	Q4	Q2	K9	K9	K8	K8	K8
					10 min	Q20	Q2	Q1	Q1	K22	K22	K22	K9	K8
					20 min	Q21	Q21	Q21	Q20	Q2	K22	K22	K21	K21
				July 12-18	5 min	Q9	Q5	Q4	K9	K9	K9	K9	K8	K8
					10 min	Q9	Q7	Q5	K22	K9	K9	K9	K8	K8
					20 min	Q9	Q9	Q5	Q4	K22	K9	K9	K9	K8
				August 20-26	5 min	Q9	Q9	Q7	Q4	K9	K9	K9	K8	K8
					10 min	Q9	Q9	Q7	Q3	K9	K9	K9	K8	K8
					20 min	Q9	Q9	Q7	Q5	Q3	K13	K10	K9	K8
DNN	K			July 1-5	5 min	Q9	Q3	Q3	Q2	Q2	K15	K15	K9	K5
					10 min	Q21	Q21	Q2	Q2	Q2	K15	K8	K8	K8
					20 min	Q21	Q21	Q21	Q15	Q13	Q9	K15	K15	K4
				July 12-18	5 min	Q21	Q21	Q9	Q4	Q2	K9	K5	K4	K3
					10 min	K9	K5	K5	K3	K3	K1	K1	K1	K1
					20 min	Q21	Q21	Q9	Q4	Q2	K9	K5	K4	K3
				August 20-26	5 min	Q21	Q9	Q8	Q7	Q4	K12	K7	K5	K3
					10 min	Q8	Q7	Q3	K12	K11	K11	K7	K3	K2
					20 min	Q2	Q2	K10	K9	K7	K3	K2	K1	K1
		XGB	K	July 1-5	5 min	Q21	Q9	Q3	Q2	Q2	K6	K5	K4	K4
					10 min	Q21	Q21	Q21	Q7	Q4	Q2	K10	K8	K1
					20 min	Q21	Q21	Q21	Q13	Q13	Q2	Q7	K13	K13
				July 12-18	5 min	Q13	Q4	Q3	K9	K8	K3	K3	K2	K1
					10 min	Q4	K9	K8	K8	K8	K8	K3	K3	K1
					20 min	Q13	Q4	Q3	K9	K8	K3	K3	K2	K1
				August 20-26	5 min	Q21	Q1	K19	K9	K8	K5	K3	K3	K2
					10 min	K9	K8	K8	K7	K5	K5	K4	K3	K2
					20 min	Q2	K8	K8	K3	K2	K2	K2	K2	K2

注: ()内は入力変数のタイムスタンプ

## 2.4 転移学習による災害時交通状態の予測

### (1) 背景・目的

災害時をはじめ、ノンリカレントな交通事象に対する短期予測の文脈においては、ほとんど機械学習モデルを援用した事例がない。この原因は、主に、災害前後の交通状態が異なる（共変量シフトと概念シフトが発生する）ことに起因する。本研究では、この問題に対し、災害前のデータを用いて構築したモデルを、災害後に得られたデータを用いて更新する転移学習モデルを開発し、その性能をナイーブな深層学習モデルと比較する。より具体的には、ソース領域(災害前の大規模データセット)において訓練

されたパラメータを、対象領域(災害後の小規模データセット)からのデータを用いてファインチューニングする。実証分析を通じて、転移学習を用いることで、交通流や時間占有率の予測精度の大幅な向上が可能であることを示す。

## (2) 対象地域と使用データ

前節と同様のエリアを対象とした分析を行うが、転移学習を実施するためにデータの範囲、期間を拡大する。具体的には、図-2.6に示す合計178台の車両感知器(LD)データを用いる。なお、前節とは異なり、5分単位に集計された交通量及び占有率のデータを用いる。本研究では、以下の2つの期間にデータを分割する。

- (a) 非災害時の状況(2016年7月1日～2018年7月5日までのデータ(~2年間))
- (b) 災害時の状況(2018年7月12日～8月16日までのデータ(~5週間))

前者のデータを利用して平時のモデルを作成し、後者のデータを用いてモデルをファインチューニングする。

災害時において短期予測モデルを構築する難しさは、災害前と災害後で交通状態が大きく異なることに起因する。図-2.7に、LD-9とLD-18について災害前後の交通量 $q$ と占有率 $k$ の値の密度分布を示す。図より、災害後に $q$ と $k$ は共に増加していることが分かる。また、LD-9の変化はLD No-18の変化に比べ、よりドラスティックであることが確認できる。これは、前節で述べたように、短距離を移動する災害関連需要がLD-9の区間で生じていたためと推測される。同様に、LD-9では、LD-18の変化に比べ、 $k$ に大きな変化が生じていることも確認できる。

更に $q$ と $k$ の関係の変化を分析するために、6日間の平日(災害前と災害後の各3日間)を選択し、両方のLDで $q$ - $k$ 図の変化を観察した(図-2.8, 図-2.9)。図より、LD-18では災害前後で $q$ - $k$ 図に大きな変化はないものの、渋滞領域のプロットが増加しており、共変量シフトが生じていることが確認できる。また、LD-9では、 $q$ - $k$ 図の形状自体が災害前後で異なることから、概念シフトが生じていることが確認できる。このことから、両地点で観測される交通状態の短期予測においては、共変量シフトや概念シフトを考慮することが可能な転移学習モデルの採用により精度が向上する可能性が高いことを示唆する。

## (3) 研究方法

モデル構造を定めるため、まず、転送学習無しでモデルの比較を行った。具体的には、LSTM(長・短期記憶)、GRU(ゲート付き回帰型ユニット)、SAE(積層オートエンコーダ)、DNN(順伝播型ニューラルネットワーク)の4つの深層学習モデルを比較した。比較の結果、LSTMモデルが最も性能の高いモデルであることが示唆されたことから、LSTMモデルを

用いて転移学習を実施した。具体的には、LSTMモデルをソース領域すなわち災害前のデータを用いて事前学習を行い、対象領域すなわち災害後のデータを使用し、正則化を用いたファインチューニングにより転移学習を行った。図-2.10にLSTMを用いた転移学習モデルの構造を示す。

採用したモデルは、1つのLSTM層(LSTM layer)と1つの全結合層(Dense fully connected layer)から構成され、そのうちLSTM層のみ転移学習段階においてファインチューニングを実施した。ハイパーパラメータの調整は、一連のハイパーパラメータをランダムに変更し探索することで実施した。本研究の目的は転移学習の有効性を検証することであるため、すべてのシナリオで同じハイパーパラメータを用いることとした。

転移学習モデルは、15分後の交通状態の予測を行うタスクに対して精度を検証した。予測は、前節のモデルと同様に、全178のLDから得られる過去60分間の $q$ と $k$ の情報を入力データ、LD-9とLD-18の $q$ 及び $k$ を出力データとして実施した。また、訓練データセットには、曜日(平日かどうか)の情報も入力データとして利用した。従って、分析には計357個の説明変数( $178 \times 2 + 1 = 357$ )を用いた。



図-2.6 対象地域と車両感知器の位置

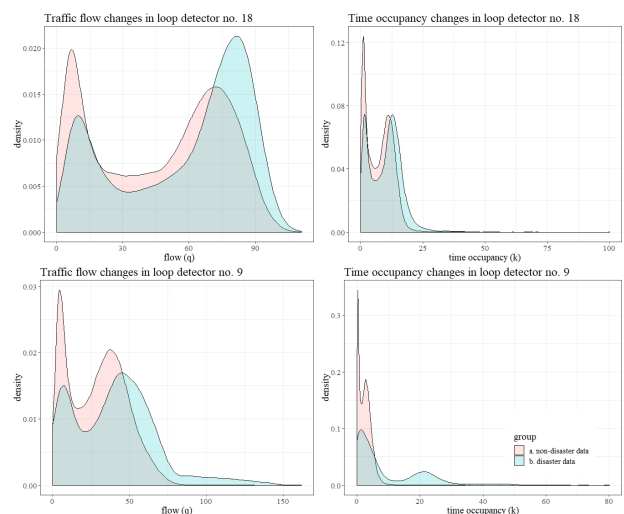


図-2.7 災害前後の交通量、占有率の変化



ソース領域（訓練のために使用した災害前の交通データ）は一定にしたが、入力変数のセットが異なるモデルの効率性を観察するために、ファインチューニングの対象ドメインとテストの対象ドメインを変化させた。災害は2018年7月6日に発生したため、2016年7月1日から2018年7月5日までの211,314データを、固定のa)災害前の状態を表すソースドメインとした。一方、災害後の利用可能なデータは、b)ファインチューニング用のデータセットとc)検証用のデータセットに分割した。転移学習の適用は、ソースドメインから得られたパラメータをファインチューニングすることで行った。ファインチューニングに用いたデータの長さは1週間から4週間であったのに対し、検証用のデータセットは1週間であったが、異なる期間で構成されている(表-2.12)。最後に、ファインチューニング用の対象ドメインと検証用の対象ドメインを変えて、合計6つの異なるシナリオを検証した。

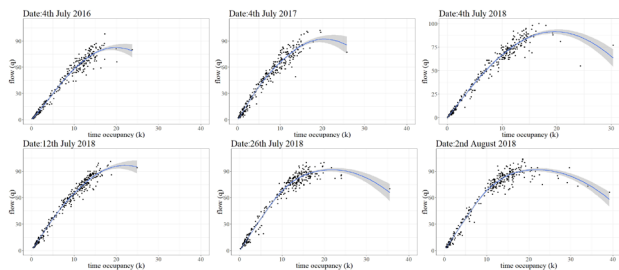


図-2.8 LD-18におけるq-k図の変化

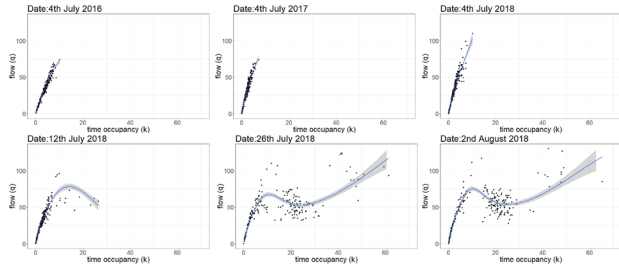


図-2.9 LD-9におけるq-k図の変化

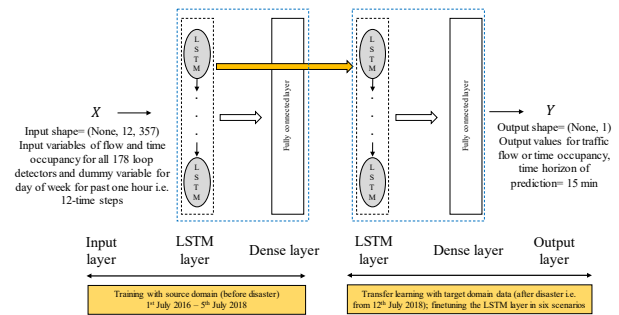


図-2.10 本研究で採用した転移学習の枠組み

#### (4) 結果

表-2.13に、各シナリオ下における転移学習による精度改善結果を示す。また、図-2.11及び図-2.12に3つのデータセットの密度分布とMAPEの改善率を示している。結果より、すべてのケースにおいて転移学習により予測精度の改善が確認された。とりわけ占有率の予測においては、30%を超える改善率を

示すケースも存在し、災害等によって生じる共変量シフト、概念シフトに対し転移学習を適用することの有効性が確認された。ただし、大幅な改善が見られたものの、実装に耐えうる予測精度であるかどうかについては、実際の適用の場面を想定した追加の検討が必要である。

表-2.12 転移学習の検証シナリオ

シナリオ	ファインチューニング用データ	検証用データ
1	2018年7月12日～2018年7月18日(1週間)	2018年7月19日～2018年7月25日(1週間)
2	2018年7月12日～2018年7月18日(1週間)	2018年7月26日～2018年8月1日(1週間)
3	2018年7月19日～2018年7月18日(1週間)	2018年7月26日～2018年8月1日(1週間)
4	2018年7月12日～2018年7月25日(2週間)	2018年7月26日～2018年8月1日(1週間)
5	2018年7月26日～2018年8月8日(2週間)	2018年8月9日～2018年8月15日(1週間)
6	2018年7月12日～2018年8月8日(4週間)	2018年8月9日～2018年8月15日(1週間)

表-2.13 転移学習による精度改善 (MAPE)

シナリオ	1	2	3	4	5	6
<b>交通流 (q) LD-18</b>						
転移学習無	21.707	22.327	27.499	27.241	18.524	21.881
転移学習有	20.094	22.325	20.790	20.497	17.096	16.600
<b>交通流 (q) LD-9</b>						
転移学習無	31.965	29.529	29.413	29.522	29.349	30.103
転移学習有	29.043	28.509	29.158	27.658	25.543	25.869
<b>時間占有率 (k) LD-18</b>						
転移学習無	50.425	56.785	46.762	47.641	56.103	60.254
転移学習有	25.883	28.505	34.818	25.565	24.063	25.580
<b>時間占有率 (k) LD-9</b>						
転移学習無	72.475	58.815	78.120	64.702	60.580	70.126
転移学習有	68.049	50.091	50.577	40.880	45.779	49.415

#### (5) まとめ

本節では、より大きなデータセット(ソースドメイン)から学習したパラメータをファインチューニングするために転移学習を採用し、様々なシナリオでナイーブ深層学習モデルとその性能を比較した。比較の結果、時間占有率の予測精度の改善率(最大32.04%)は、交通流における改善率(最大6.75%)に比べて大きいことが確認された。また、ソース領域、ファインチューニングのための対象領域、そしてデータセットをテストするための対象領域の間の類似性が転移学習モデルの性能を向上させ得ることが示唆された。

## 2.5 OD交通量の短期予測：深層学習

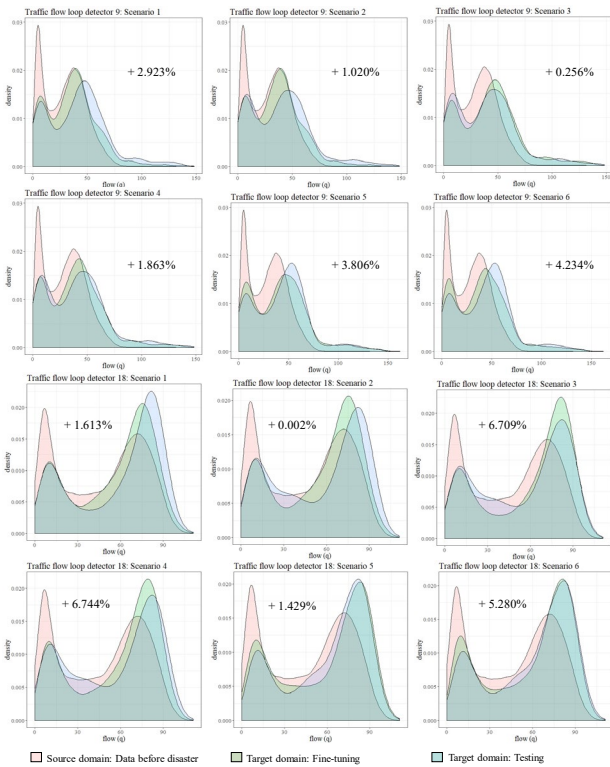
OD交通量の短期予測においても、交通状態の短期予測と同様に、リアルタイムに時々刻々と入手できるパッシブデータを用いた学習アルゴリズムの開発が望ましい。本節では、携帯電話の位置情報データ（モバイル空間統計データ）を使用し、前日同時刻までのデータから、24時間後のOD交通量を予測するモデルを複数構築し、その精度を比較した。比較により、OD交通量予測にあたって、深層学習の予測精度を実証的に明らかにした。

### (1) 使用データの概要

本研究では、モバイル空間統計データを活用してOD交通量を予測する。モバイル空間統計データとは、電気通信サービスを提供する過程で発生する運用データを、社会の情報基盤の構築・整備を目的として統計化した特定の個人を識別できない情報（データ）である。公共分野、学術研究分野、産業分野などを提供先として想定し、運用データの一部である位置データおよび属性データに、非識別化処理、集計処理、秘匿処理を行うことにより作成されたデータである。本研究開発では、モバイル空間統計データを用いて、ゾーン間のOD交通量を把握したデータを用いて、短期需要予測を行う。OD交通量を集計するにあたって対象としたゾーンは、呉市・広島市を中心とした30ゾーンである(図-2.13参照)。データの集計期間は、災害発生前にあたる2017年の6月から10月、および、災害発生後にあたる2018年の6月から10月である。データ単位は1時間である。モデル構築にあたっては、モデル精度の確認、および災害時への適用可能性の検証のため、4つのデータセットを設定する(表-2.14)。データセット1は災害発生前の日常データである。データセット1へのモデル適用結果から、災害後との比較のため、モデル精度の参照点を得る。データセット2~4は災害後データである。データセット2~4と学習データを短くする。深層学習では学習データが少ないほどモデル精度が通常悪くなる。一方で、災害発生直後ほど、混乱が大きく、需要予測の重要性が高い。本研究では、学習データの期間の異なる3つのデータセットの結果を比較し、深層学習モデルの災害復旧期のOD交通需要予測への適用可能性を明らかにする。

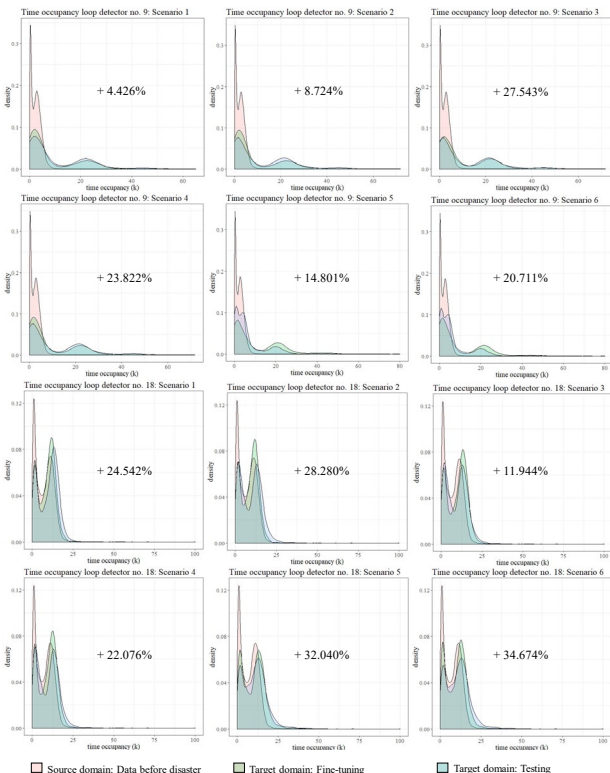
### (2) モデルと適用結果

本研究開発では、RNN系のモデルを適用し、あるゾーン間のOD交通需要を予測する。インプットとしては、自ODのd日~1日前までの観測データ、逆向きODのd日~1日前までの観測データ、土日祝日のダミー変数、構築モデルにより予測した自ODの1日前~1時間前までの予測データである。これにより、24時間前までの観測データが手に入る状況での自己回帰型のOD交通需要の短期予測モデルを構築する。モデルイメージを図-2.14に示す。また、RNN系のモデルとしてRNN (Recurrent neural network), GRU (Gated



注:パーセント値はナイーブLSTMを比較して転移学習適用後のMAPEの改善率を表している。

図-2.11 交通量の分布と転移学習による性能の改善



注:パーセント値はナイーブLSTMを比較して転移学習適用後のMAPEの改善率を表している。

図-2.12 占有率の分布と転移学習による性能の改善

Recurrent Unit), GRU+Dropout, LSTM (Long Short term Memory), LSTM+Dropoutの5種類を適用する。また、適用対象として、観測されたOD交通量のボリュームや被害状況を考慮し、5ODペア (a. 広島市中区→広島市南区, b. 呉市天応→呉市中央, c. 呉市天応→広島市南区, d. 呉市阿賀→呉市中央, e. 呉市阿賀→広島市南区) を抽出し、適用した。

まず、a. 広島市中区→広島市南区のODペアを対象に、災害前データセット(1710)及び災害後4か月分のデータセット(1810)を用いて、モデル構築及び予測結果の検証を行う。なお、計算にあたっては、理研 AIP センターの雷電(詳細: <https://pr.fujitsu.com/jp/news/2018/04/20.html>)を利用した。モデル適用の結果を表-2.15に示す。隠れ層数を80, 100, 120, インプットする観測データ日数を4, 5とし、それぞれ計算した。黄色の網掛けは良い結果(MAEが300以下)であることを示している。災害前・災害後に関わらず、良い結果を示したモデル設定は、LSTM及びGRU (Dropoutなし) のインプットする観測データ日数が4日であった。隠れ総数は80, 100のどちらでも同程度の良好な結果を得ている。これらのモデル設定を他のODペア・データセットに適用する。また、比較によりRNNよりもLSTM, GRUが良い結果となった点、Dropoutなしの方が良い結果となった点、インプットデータの日数は4日で十分であった点が明らかになった。災害後データセット(1810)のテストデータにおける観測したOD交通量とモデル予測したOD交通量を図-2.15と図-2.16に示す。図の青線はモデル予測による値、黒線は観測データ、赤線は両者の差の絶対値を示している。実データは完全に周期性があるわけではなく、モデルを用いた予測が必要であることがわかる。モデル予測によりどの時間帯でも精度の高いOD交通量を得ているといえる。ただし、一部の日(例えば10月28日)のピーク時において、比較的大きな差が生じている場合がある。




図-2.14 自己回帰型の深層学習モデル

表-2.15 適用結果

Method	Num. of hidden	Dropout	Input [day]	Test: 1710		Test: 1810	
				RMSE	MAE	RMSE	MAE
Base				452	272	608	340
RNN	80		4	423	320	386	251
	80	apply	4	1000	794	804	605
	80		5	404	312	456	299
	100		4	381	261	436	310
	100	apply	4	974	753	523	326
	100		5	502	373	618	411
LSTM	80		4	359	242	419	287
	80	apply	4	481	327	702	453
	80		5	494	368	460	340
	100		4	342	229	338	230
	100	apply	4	537	376	659	400
	100		5	558	357	411	302
GRU	120		5	498	367	446	327
	80		4	407	259	369	248
	80	apply	4	610	445	744	551
	80		5	802	614	470	329
	100		4	486	297	394	273
	100	apply	4	509	380	735	526
	100		5	518	363	433	306
	120		5	535	367	376	264




図-2.13 対象ゾーン (広島市・呉市周辺)

表-2.14 使用したデータセット

データセット	データの種類	データ期間
1. 災害前 (1710)	学習	2017年6月~9月
	検証	2017年10月
2. 災害後1 (1810)	学習	2018年6月~9月
	検証	2018年10月
3. 災害後2 (1809)	学習	2018年6月~8月
	検証	2018年9月
4. 災害後3 (1808)	学習	2018年6月~7月
	検証	2018年8月




図-2.15 観測データ (2018年10月) とモデル予測 (LSTM, 隠れ層100) の比較




図-2.16 観測データ (2018年10月) とモデル予測 (GRU, 隠れ層80) の比較

## 2.6 OD交通量の短期予測： entropy tucker model

本節では、機械学習手法と交通理論との整合性を担保したモデル開発を試みる。具体的には、OD交通量の予測モデルとして広く使われているentropyモデルと、交通分野への適用が広がりつつある機械学習分野の一手法であるTucker decompositionを統合したモデル開発を行う。また、広島都市圏において普及している公共交通ICカードデータ（PASPYデータ）を活用した実証分析を行い、提案手法の妥当性を予測精度、解釈可能性の観点から検証する。検証を通じて、提案手法は、従来手法に比べて、(1)大幅な精度向上（13%の精度向上）が可能であること、(2)高い解釈性を有することを示す。

### (1) はじめに

観測技術の向上に伴い、様々なPassive dataが利用できるようになってきている。これらのデータを効率的に処理できる機械学習手法の発展も相まって、UberやLyftをはじめとするRide Hailing サービスのマッチングアルゴリズムや交通信号制御といった短期予測が必要とされる文脈で大きな成功を収めている。また、交通現象の理解を深める点においても、これらのPassive dataと機械学習手法の組み合わせは大きな成功を収めている<sup>11)</sup>。一方、交通計画への活用については、十分に進んでいないのが現状であろう。この原因は、機械学習手法の盲目的な適用では交通理論と整合的な形で結果を解釈・説明できないことに起因するところが大きい。長期の交通計画に活用するためには、Chen et al. (2016)<sup>11)</sup>が指摘するように、交通理論研究の中で蓄積されてきた理論研究を組み込んだ機械学習手法の構およびその政策議論への適用が求められている。

機械学習手法に交通理論との整合性を求めた研究は幾つかの例外を除き多くはない。Brathwaite et al. (2017)<sup>12)</sup>は、“the fields of statistics, computer science, and machine learning have created numerous methods for modeling discrete choices, while these newer methods have not been derived from or linked with economic theories of human decision making”と指摘し、決定木分析のミクロ経済的理論付けの可能性について議論している。Sifringer et al. (2018)<sup>5)</sup>は、離散選択モデルの構築において、交通の理論基礎との整合性を重視すべきknowledge-drivenの要素と、精度向上のために深層学習の仕組みを援用するdata-drivenの要素の双方を併せ持ったLearning Multinomial Logit Modelを提案している。各国でAIガイドラインが整備され、政策の意思決定の文脈での機械学習の利用にロジックとreasoningが重要視されてきていることを鑑みると、以上のような交通理論と整合的な機械学習手法を開発・利用することが、とりわけ理論的基礎付けが重要となる交通計画においては重要になる。

本研究では、以上の背景を踏まえ、Tucker decompositionをEntropy modelと整合するように拡張し、交通理論と整合的な解釈が可能な機械学習

モデルの開発を試みる。

本研究の貢献は下のとおりである。

- (1) 既存のNTFモデルとEntropyモデルの間に存在する数学的関連性に言及し、移動データ解析に対する両モデルの利点を保持した新たなNTFモデルを提案する。提案モデルは、移動データに潜在する距離抵抗の影響を適切に分離でき、都市の本質的な移動パターンを抽出できる。この過程で、移動パターンごとの潜在的距離減衰パラメータが推定できる。
- (2) 提案モデルにより定義される最適化問題を解くための最適化アルゴリズムを提案する。この最適化問題は、通常のNTFに距離減衰項が付加されたものとなっており、既存のNTF用の最適化アルゴリズムが適用できない。そのため、NTFのための最適化と距離減衰パラメータの最適化を交互に繰り返す新たな交互最適化アルゴリズムを導出する。また、その収束性についても議論する。
- (3) 日本の広島周辺の私鉄から得られた大規模スマートカードデータ（半年、1000駅（領域化されていない）、4,500万trips）を対象に提案モデル、及び既存モデルを適用し、得られた代表的な移動パターンの分析・評価を行う。結果として、既存モデルは同領域内での移動が多いという結果となるのに対し、提案モデルでは通勤時間帯に中心部近郊領域から中心部への移動が多いといった、より本質的かつ解釈性の高い結果が得られることを確認する。また、通勤や休日昼の移動といった移動パターンごとに得られる距離減衰（移動抵抗）パラメータが、データに則した妥当なものであることを検証する。

### (2) 提案モデル

以下のモデルの導出において扱うテンソル演算子を利用する変数・演算子の定義を示す。

表-2.16 変数・演算子の定義

Notation	Description
$\mathbf{X}$	$N$ -way tensor
$X$	matrix
$A^{(n)}$	mode- $n$ matrix in a tensor decomposition model
$\times_n$	mode- $n$ product
$\circ$	outer product
$\odot$	Hadamard product

提案する距離減衰項付きNTDモデルは以下のとおりである。

$$\mathbf{X} = \sum_{j_1}^{J_1} \cdots \sum_{j_N}^{J_N} s_{j_1 \dots j_N} \mathbf{a}_{j_1}^{(1)} \circ \cdots \circ \mathbf{a}_{j_N}^{(N)} \odot f^{(j_1 \dots j_N)}(\mathbf{D}) \quad (2-1)$$

ここで、 $\mathbf{a}_{j_1}^{(n)}$ はモード行列 $A^{(n)} \in \mathbb{R}_+^{I_n \times J_n}$ の $j_n$ 番目の列ベクトル、 $\mathbf{D} \in \mathbb{R}_+^{I_1 \times \cdots \times I_N}$ は $\mathbf{X}$ の各要素に対して定義される距離（移動コスト）、 $f^{(j_1 \dots j_N)}: \mathbb{R}_+^{I_1 \times \cdots \times I_N} \rightarrow$

$\mathbb{R}_+^{1 \times \dots \times 1 \times N}$  は基底の組  $\{j_1, \dots, j_N\}$  毎に定義される、距離  $\mathbf{D}$  を補正する関数である。

提案手法における距離補正関数  $f^{(j_1 \dots j_N)}$  は任意の関数が利用可能だが、本論文では空間的相互作用モデルの代表的なモデルであるエントロピーモデルを参考に、以下の関数を採用する。

$$f^{(j_1 \dots j_N)}(\mathbf{D}) = \exp(-\beta_{j_1 \dots j_N} \mathbf{D}) \quad (2-2)$$

ここで  $\beta_{j_1 \dots j_N}$  は基底の組  $\{j_1, \dots, j_N\}$  ごとの距離減衰パラメータである。式(2-1)を採用した場合の提案モデルは以下のようになる。

$$\mathbf{X} = \sum_{j_1}^{I_1} \dots \sum_{j_N}^{I_N} s_{j_1 \dots j_N} \mathbf{a}_{j_1}^{(1)} \circ \dots \circ \mathbf{a}_{j_N}^{(N)} \odot \exp(-\beta_{j_1 \dots j_N} \mathbf{D}) \quad (2-3)$$

以降、このモデルを **entropy Tucker model** と表記する。本提案手法は、NTFの複雑な特徴を抽出できる利点と **entropy** モデルの現実の移動を良く表現するという利点を兼ね備えたモデルとなっていることが期待される。

以上の拡張したモデルの解を得るために、Kim and Choi (2007)<sup>14)</sup> が提案した、NMF用の最適化方法の1つである **multiplicative updating algorithms (MUA)** (Lee and Seung, 2000) をNTD向けに拡張したアプローチを採用する。NTD向けのMUAは、各モード行列  $\mathbf{A}^{(n)}$  とコアテンソル  $\mathbf{S}$  を、他をすべて固定したもとの1つずつ更新していくことを繰り返す交互最適化アルゴリズムである。MUAを利用すると、モード行列とコアテンソルの全要素の初期値が非負値であれば、得られる結果も必ず非負値となる。また、各ステップで目的関数の値は非増加であるため、高い収束性を示す。具体的なアルゴリズムは **Algorithm 1** に示す通りである。

### Algorithm 1

**Algorithm 1** Alternative Optimization Algorithm for Proposed Model  
**Input:**  $\mathbf{X}, \mathbf{D} \in \mathbb{R}_+^{I_1 \times \dots \times I_N}$ ,  $\{j_1, \dots, j_N\}$ ,  $\beta_{\text{init}}, \epsilon_{\text{max}}, \epsilon'_{\text{max}}, \text{tol}, \text{tol}'$   
**Output:**  $\mathbf{S} \in \mathbb{R}_+^{I_1 \times \dots \times I_N}$ ,  $\mathbf{A}^{(n)} \in \mathbb{R}_+^{I_n \times J_n}$ ,  $\beta_{j_1 \dots j_N}$   
*Initialization:*  $\mathbf{S}$  がすべての  $\mathbf{A}^{(n)}$  の各要素を 0 より大きな任意の値にセット、すべての  $\beta_{j_1 \dots j_N}$  を  $\beta_{\text{init}}$  にセット。  
1: for *epoch* = 1 to  $\epsilon_{\text{max}}$  do  
2:  $\mathbf{C}^{(j_1 \dots j_N)} = \exp(-\beta_{j_1 \dots j_N} \mathbf{D})$   
3: for  $n = 1$  to  $N$  do  
4:  $\mathbf{A}^{(n)} \leftarrow \mathbf{A}^{(n)} \odot \frac{\sum_{(j_1, \dots, j_N)} (\frac{\mathbf{X}}{\mathbf{C}})^{(j_n)} \otimes \mathbf{S} \otimes \mathbf{A}^{(1)} \otimes \dots \otimes \mathbf{A}^{(n-1)} \otimes \mathbf{A}^{(n+1)} \otimes \dots \otimes \mathbf{A}^{(N)} \otimes \mathbf{C}}{\sum_{(j_1, \dots, j_N)} \mathbf{S} \otimes \mathbf{A}^{(1)} \otimes \dots \otimes \mathbf{A}^{(n-1)} \otimes \mathbf{A}^{(n+1)} \otimes \dots \otimes \mathbf{A}^{(N)} \otimes \mathbf{C}}$   
5: end for  
6:  $\mathbf{S} \leftarrow \mathbf{S} \odot \frac{\sum_{(j_1, \dots, j_N)} (\frac{\mathbf{X}}{\mathbf{C}}) \otimes \mathbf{S} \otimes \mathbf{A}^{(1)} \otimes \dots \otimes \mathbf{A}^{(N)} \otimes \mathbf{C}}{\sum_{(j_1, \dots, j_N)} \mathbf{A}^{(1)} \otimes \dots \otimes \mathbf{A}^{(N)} \otimes \mathbf{C}}$   
7: for *iteration* = 1 to  $\epsilon'_{\text{max}}$  do  
8: update all  $\beta_{j_1 \dots j_N}$  using a gradient method  
9: if [Improvement ratio by the gradient method] <  $\text{tol}'$  then  
10: break  
11: end if  
12: end for  
13: if [Improvement ratio in this epoch] <  $\text{tol}$  then  
14: break  
15: end if  
16: end for

### (3) ケーススタディの設定

実証分析では広島においく利用されている公共交通ICカードPASPYのトランザクションデータを用いる。トランザクションから得られる情報には、ユーザ ID、空間的な情報である乗車駅/降車駅 ID と、

時間的な情報である 乗車/降車時刻が含まれている。本ケーススタディでは、広島市中心部近郊の1,000駅を対象に、2017/11/16から2018/06/30 で得られた全トランザクションのデータを利用する。対象となる領域の衛星写真、駅の空間的な分布・利用人数のランキングを図-2.17に示す。このトランザクションから、O(origin stations; 1st way), D(destination stations; 2nd way), T(transaction time at an origin station; 3rd way), K(kind of day - weekday or holiday; 4th way)の四次元テンソルを作成し、各次元の組み合わせに対する総トリップ数をテンソル分解モデルへの入力とする。作成されたテンソルの各次元の基礎情報を表-2.17に示す。Tは60分刻みで離散化されている。なお、前処理として、同一ユーザの降車時刻から次の乗車時刻が 30 分以内である、連続したトランザクションは乗り換えと判定、1つのトリップとして統合した。前処理後に得られる総トリップ数は約 4,500 万で、そのうち 78.9%が平日のトリップである。また、テンソルのスパース性(要素の値が 0 である割合)は 96.2%で、最大の要素の値は 40,818 である。

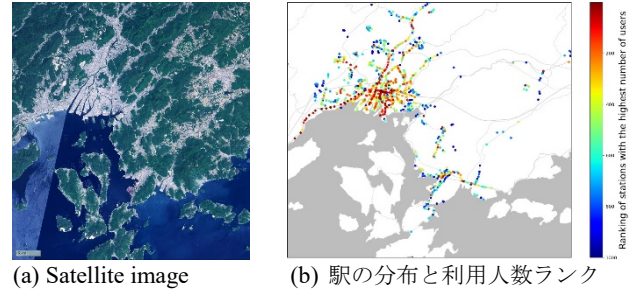


図-2.17 データの対象範囲の衛星写真および駅の空間的分布・利用人数ランキング

表-2.17 テンソルデータの構成

Way	# of Dim.	Description
O: Origin Station	1,000	1st way
D: Destination Station	1,000	2nd way
T: Time of day	20	3rd way; (1) 5:00-6:00,..., (20) 24:00-25:00
K: Kind of day	2	4th way; (1) weekday, (2) holiday

### (4) 分析結果

本節では提案(proposal)モデルと既存(normal)モデルの分解性能の比較評価を行う。分解性能の評価は、フィッティング性能、及び予測性能の両面から行う。評価方法は以下のとおりである。はじめに、スマートカードデータの一部をランダムにマスク、すなわち未観測値であるとした。今回はマスクする要素数は全要素数の 10%とした。次に、収束性の確認のために収束判定を無効にした上で 1,000epoch に渡って両モデルをこのマスクデータに適用した後、元データと復元したテンソル間のマスクされていない要素の平均 I-divergence を用いてフィッティング性能を評価した。

結果を図-2.18に示す。ここで図中の”-fit”はフィッティング,”-est”は予測性能を意味し、表示され

ている値は 1,000epoch 時の平均 I-divergence である. 1,000epoch の時点で, 提案モデルは 既存モデルと比較して, フィッティング, 予測性能が共に約 13%向上したことが確認できた. このことから, 今回用いた スマートカードデータにも, 一般的な交通データと同様に距離により移動量が減衰するという特性が内在しており, その影響を距離補正項で吸収できる提案モデルの方が, 高いフィッティング性能を示すことが確認できた. 加えて, 予測精度も優れていることから, フィッティング性能の高さが, パラメータ $\beta$ が増えたことによるオーバーフィッティングによるものではないことが確認できた.






図-2.18 両モデルのフィッティング, 予測性能



(a) normal




(b) proposal

図-2.19 両モデルの各時間基底の各時間帯の値


T次元とK次元に関するmode matrixの値を図-2.19, 図-2.20に示す. また, 提案モデルで推定された  $T-K$  ごとの距離減衰パラメータは 表-2.19のとおりとなった.

表-2.19 時間, 平日/休日基底ごとのベータの値

	K1	K2
T1	11.46	11.21
T2	13.01	11.46
T3	8.99	8.78
T4	10.16	12.43



(a) normal



(b) proposal

図-2.20 両モデルの各平日/休日基底の値

得られたO次元とD次元のmode matrixを, 各行ごとに足して1になるように正規化した. 正規化されたmode matrix の各要素は, 各駅が各基底に属する割合を意味することになる. つまり, 同一の normalized mode matrix 内で類似しているベクトルを持つ駅同士は, 都市内で空間的に似たような役割を持っているといえる. 図-2.21, 図-2.22に, 各駅が持つ各 normalized mode matrix の各基底の値を, 駅の座標上にプロットした結果を示す. なお, 円の面積が大きいほど, その基底の値が大きい(基底が意味する役割を強く持つ)ことを示す.

両モデルから得られたコアテンソルを, T, K の組み合わせごとに OD 方向に切り出して得られる行列をヒートマップ形式で表示したものを図-2.23, 図-2.24 に示す. なお, コアテンソルの値は分散が大きいいため, 見やすさのため  $\log_{10}$ を通した値を用い



(a) normal-O1 (b) normal-O2 (c) normal-O3 (d) normal-O4 (e) normal-O5



(f) normal-D1 (g) normal-D2 (h) normal-D3 (i) normal-D4 (j) normal-D5

図-2.21 normal モデルの各 O,D の基底に対する貢献度



(a) prop-O1 (b) prop-O2 (c) prop-O3 (d) prop-O4 (e) prop-O5



(f) prop-D1 (g) prop-D2 (h) prop-D3 (i) prop-D4 (j) prop-D5

図-2.22 提案モデルの各 O,D の基底に対する貢献度

て描画した。また、見やすさのため weekday と holiday でヒートマップの最大値を変えて描画していることに注意する必要がある。

以上の分解結果を元に、広島市内の人の移動を解釈する。はじめにnormalモデルの結果を用いた解釈を行う。normalモデルのコアテンソルの値(図3.4-7)は、どのT次元に対してもO1-D1,...,O5-D5の組以外が大きな値を持つことはない。よって、広島市では  $O_i$  に属する駅から、 $D_i$  に属する駅への移動が大多数であると解釈される。ここで、各O,Dの基底に属する駅の分布を示す図3.4-5を見ると、すべての  $O_i$ - $D_i$ ペアでほぼ同一の分布をしていることがわかる。このことから、normalモデルを用いた移動分析では、広島市内では、同一の領域内での移動が代表的な移動である、

という解釈がなされる。この結果は、先行研究<sup>13)</sup>とおおよそ合致している。一方提案モデルでは、weekday (K1) における morning time (T3) では、O2-D2の値が最も大きいことから、都心部の周辺から都心部への通勤行動と解釈可能な移動が抽出されるなど、解釈可能性の高い結果が得られた。また、パッシングデータのみから移動パターンごとの距離減衰パラメータの推定が可能であることから、提案モデルの優位性は明らかと思われる。

#### (5) おわりに

本研究では、OD交通量の予測モデルとして広く使われているentropyモデルと、交通分野への適用が広

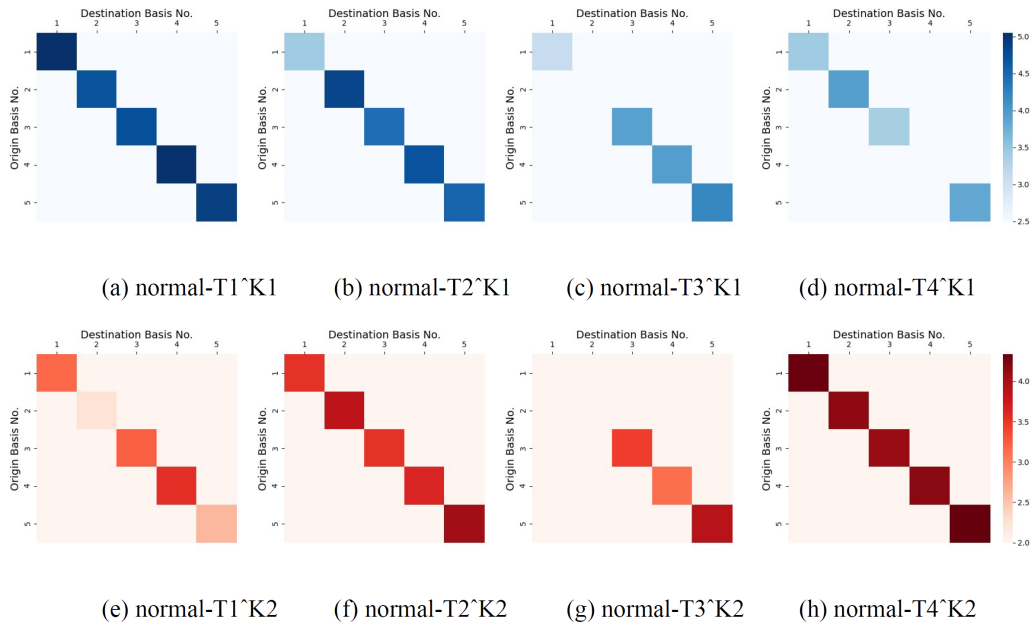


図-2.23 normal モデルの  $T^K$  ごとのコアテンソルの値 (log-scale)

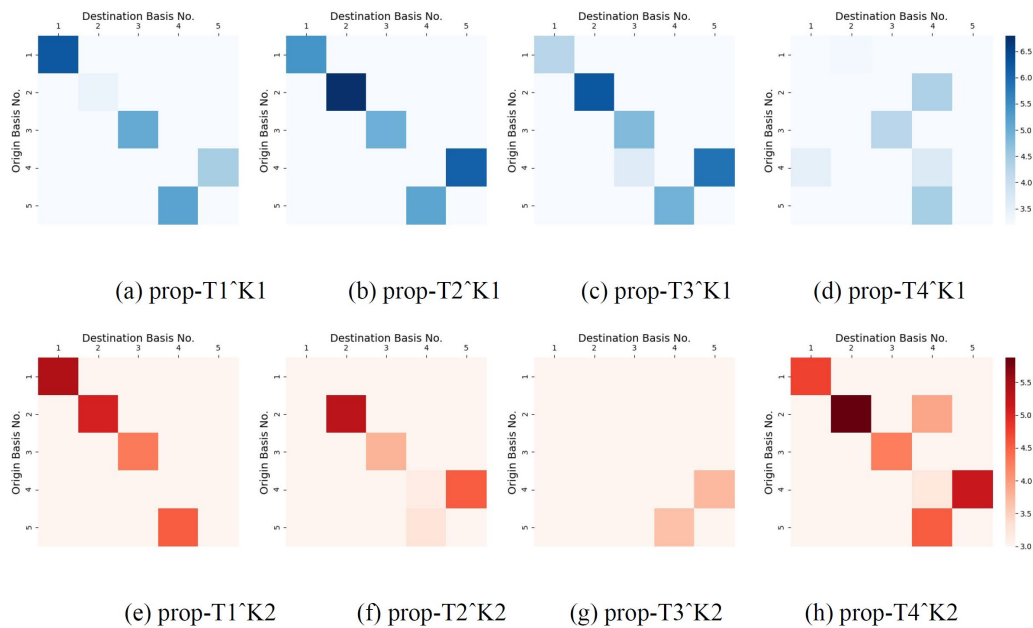


図-2.24 提案モデルの  $T^K$  ごとのコアテンソルの値 (log-scale)

がりつつある機械学習分野の一手法である Tucker decomposition を統合したモデル開発を行った。広島都市圏において普及している公共交通ICカードデータ (PASPYデータ) を活用した実証分析の結果、提案手法は、従来手法に比べて約13%の精度向上が確認され、また、従来モデルに比べ高い解釈性を有することが示唆された。

#### 参考文献

- 1) Do, L.N.N., Taherifar, N., Vu, H.L., 2019. Survey of neural network - based models for short - term traffic state prediction. Wiley Interdiscip. Rev. Data Min. Knowl. Discov. 9, e1285
- 2) Nguyen, H., Kieu, L.-M., Wen, T., Cai, C., 2018. Deep learning methods in transportation domain: a review. IET Intell. Transp. Syst. 12, 998–1004.
- 3) Wang, Y., Zhang, D., Liu, Y., Dai, B., Lee, L.H., 2019. Enhancing transportation systems via deep learning: A survey. Transp. Res. Part C Emerg. Technol. 99, 144–163.
- 4) Varghese, V., Chikaraisi, M., Urata, J. (2020) Deep Learning in Transport Studies: A Meta-Analysis on the Prediction Accuracy, Journal of Big Data Analytics in Transportation, Vol. 2, 199–220.
- 5) Sifringer, B., Lurkin, V., Alahi, A., 2018. Enhancing Discrete Choice Models with Neural Networks, in: HEART



2018–7th Symposium of the European Association for Research in Transportation Conference.

- 6) Chikaraishi, M., Garg, P., Varghese, V., Yoshizoe, K., Urata, J., Shiomi, Y., Watanabe, R. (2020) On the possibility of short-term traffic prediction during disaster with machine learning approaches: An exploratory analysis, *Transport Policy*, 98, 91-104.
- 7) Van Arem, B., Kirby, H.R., Van Der Vlist, M.J.M., Whittaker, J.C., 1997. Recent advances and applications in the field of short-term traffic forecasting. *Int. J. Forecast.* 13, 1–12.
- 8) Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32.
- 9) Cristianini, N., Shawe-Taylor, J., 2000. An introduction to support vector machines and other kernel-based learning methods. Cambridge university press.
- 10) Chen, T., Guestrin, C., 2016. Xgboost: A scalable tree boosting system, in: *Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining*. ACM, pp. 785–794.
- 11) Chen, C., Ma, J., Susilo, Y., Liu, Y., and Wang, M. (2016). The promises of big data and small data for travel behavior (aka human mobility) analysis. *Transportation research part C: emerging technologies*, 68:285–299.
- 12) Brathwaite, T., Vij, A., and Walker, J. L. (2017). Machine learning meets microeconomics: The case of decision trees and discrete choice. *arXiv preprint arXiv:1711.04826*.
- 13) Sun, L. and Axhausen, K. W. (2016). Understanding urban mobility patterns with a probabilistic tensor factorization framework. *Transportation Research Part B: Methodological*, 91:511–524.
- 14) Kim, Y.-D. and Choi, S. (2007). Nonnegative tucker decomposition. In *2007 IEEE Conference on Computer Vision and Pattern Recognition*, pages 1–8. IEEE.

## 第3章 新たな観測・介入ツールの開発と交通需要マネジメントへの適用

### 3.1 はじめに

自動観測されるパッシブデータは、移動者の属性や目的、利用交通手段の判別が難しいことに加え、交通行動結果のデータであることから、移動者の交通手段変更や目的地の変更、行動の取りやめなど、最終的な行動に至ったプロセスの把握が困難である。さらに、交通供給不足により需要が潜在化している場合、観測された需要パターンに合わせた交通サービスの供給は最適解とはならない可能性が高く、パッシブデータにより得られる顕在選好情報のみで適切な交通マネジメントを実現することは容易ではない。

そこで本章では、以上のパッシブデータの欠点を補うべく、新たな観測・介入ツールを開発する。3.2節では、RP行動結果をもとにリアルタイムで政策に対する選好情報を尋ねるreal-time context-aware 表明選好(SP)調査手法を開発し、3.3節にて混雑課金の影響評価に適用した結果を報告する。3.4節では、個々の時間価値の異質性を手掛かりに、パーソナライズされたインセンティブを生成するためのアルゴリズムを開発し、3.5節では生成したインセンティブが付与される状況（行動結果に応じて謝金額を増減させることで対応）下及びレコメンデーション情報提供下における交通行動を観測・評価する介入実験の実施結果を報告する。3.6節では、GojekやGrabといったマルチサービス交通プラットフォーム(MSTPs)が生活・交通行動に及ぼす影響を確認することを目的に、インドネシア・ジャカルタ市を対象としたプローブパーソン(PP)-表明選好(SP)調査を設計・開発し、3.7節にて特にオンラインフード配達サービスの影響評価に焦点を当てた分析結果を報告する。

### 3.2 Real-time context-aware表明選好(SP)調査手法の提案

#### (1) 背景・目的

スマートフォンのGPS機能で調査対象者の移動軌跡を収集するとともに移動目的や利用交通手段を把握できるプローブパーソン(Probe Person; PP)調査は、移動者が能動的に発信する情報を取得すること

ができるアクティブデータであるため、移動者の属性と交通行動の紐付けが可能である。また、こういったPP調査の被験者に追加的に選好意識調査を尋ねることにより、交通マネジメント上必要な情報を得ることが可能と考えられる。

以上のような問題意識から、PP調査結果をもとにSP調査を実施するcontext-aware SP調査が提案されている<sup>1)2)</sup>。また、類似の調査手法として、非観測文脈要因を考慮した上でSP調査に回答してもらう手法として、RP調査で選択した各選択肢の属性水準を変化させた上で選好を尋ねる調査方法(SP-off-RP調査)<sup>3)</sup>が提案されている。これらの調査方法の大きな利点は、例えば「重要な会議に参加しようとしている」、「帰りに子供を迎えに行く必要がある」といった実際の行動の意思決定に影響している文脈要因を考慮した上でSP調査に回答してもらうことが可能になる点である。こういった非観測文脈要因を無視してしまうと、例えば新たな交通手段の利用を過剰に見積もってしまうなどのバイアスが生じることが報告されており<sup>4)</sup>、交通マネジメント上必要な情報入手する際においては、簡便かつ複雑な文脈要因に配慮した回答が得られるよう設計された調査手法の採用が求められる。

時間の経過とともに記憶が曖昧になることから、以上に見た文脈要因の影響は、実際のRP行動実行時とSP設問回答時の間に時間差ができればできるほど、弱くなっていく可能性がある。こういった回答遅れに伴うSP回答のバイアスを減少させることを目的に、本研究では、リアルタイムに（すなわち、RP行動直後に）SP設問を回答してもらう機能を既存のPP調査システムに新たに追加したアプリを開発するとともに、実証実験を通じてリアルタイムで回答してもらうことの意義（リアルタイムで回答しないことにより生じるバイアスの程度）を実証的に示す。

具体的に検証した仮説は以下の3点である。

1. 回答遅れにより、選択結果に系統バイアスが生じる可能性が高いこと、
2. 回答遅れは、RP属性がSP回答時に与える影響が小さくなる調整変数として働く傾向があること、

3. 回答遅れは、SP属性がSP回答時に与える影響が大きくなる調整変数として働く傾向があること

(2) 開発したアプリの概要

本研究では、既存のプロブパーソンアプリをベースにWebアンケートフォームと組み合わせた介入型プロブパーソンの開発を行った。既存のプロブパーソンアプリは、経年的に多くの調査実績を有するトランスフィールド株式会社のアプリを活用した。介入型プロブパーソンの開発にあたっては、既存のアプリに対して、混雑課金に対するSP調査を実施するため、取得するプロブデータを用いてエリア判定のプログラムを新たに改修するとともに、SP調査対象者を判別するためのエリア滞在時間判別（5分以上の滞在判定）、モード判定、移動時間帯判定等のプログラムを開発した（図-3.1）。


PP 調査		+	SP 調査
基盤システム (既存)	開発機能		開発機能
プロブパーソンアプリ 	新たに開発する要素技術 ①エリア判定 ②エリア内滞在時間判定 ⇒5分以上の滞在対象 ③モード判定 ⇒自動車を対象 ④移動時間帯判定 ⇒プライシング（課金）時間帯判定		Web アンケート開発 ①SP 調査対象者への配信・リンク機能 ②未回答者へのプッシュ通知機能（Android版のみ） ③未回答・回答の判別機能

図-3.1 アプリ開発の全体像

PP調査に関する開発機能のうち、①エリア判定、②エリア内滞在時間判定及び④移動時間帯判定は今回、新たにシステム改修を行ったため、以下に検討仕様を詳細に示す。（③のモード判定は既存のモード選択に対する簡易なフィルター機能のため省略）

**エリア判定**：ロードプライシングに対する行動変容を評価するSP調査を実施するにあたり、プライシングエリア内を実際に移動したかどうかを判定し、該当エリア内を移動した被験者に対してのみSP調査アンケートを配信（リンク）するための機能を開発した。実証実験にて採用したプライシングエリアを図-3.2に示す。

**エリア内移動時間判定**：ロードプライシングを行う対象行動として、一定時間内以上、エリア内を移動した行動のみを対象とするための移動時間判定の機能を開発した。

**移動時間帯判定**：混雑課金の性質を鑑み、6:00~19:00の移動に対しては、SP調査対象としそれ以外の時間帯は対象外とした。



(a) 広島



(b) 熊本

図-3.2 混雑課金想定エリア

図-3.3にSP調査画面の例を示す。また、表-3.1にSP調査の提示内容と選択肢、表-3.2に仮想状況の設定方法を示す。SPの属性はpivoting SP調査と同様の手順で、RP情報を参照しながら生成する仕組みを採用した。SP設問では、回答者に移動軌跡などの実際の行動履歴と、その行動を基に設定した仮想状況を提示し、課金が行われた場合の行動変容を6つの選択肢から1つ選択させた。SP設問の提示内容と行動の選択肢を表-3.1に示す。表中で示しているように、仮想的な通行料金や課金による移動の短縮時間等は、実際の行動などを基にランダムに設定した。

2つの調査を組み合わせることで、対象者は実際の行動を関連付けた上でSP設問に回答するため、データの信頼性の向上が期待できる。また、トリップ完了直後にSP設問を尋ねることにより、記憶劣化に伴う精度の低下を回避している。

提示した仮想状況の設定方法の詳細を表-3.2に示す。時間帯については交通量を考慮し4つの時間帯に分け、すべての時間帯の通行料金をSP設問において提示した。通行料金の決定方法は2種類用意し、調査対象期間の半分で入れ替わっている。料金の式からわかるようにプラン1はランダムに料金を設定しているのに対し、プラン2はエリア内の滞在時間も考慮した料金が設定されている。X, Y, M, tの設定については、標本数を一定程度確保できる場合、一部実施要因計画を用いるよりもランダムに水準を生成



(a) An example of SP question

(b) A hypothetical pricing area

図-3.3 SP調査の画面

する方が効率的であることを示した既往研究の知見を踏まえ、後者を採用した。

以上構築したアプリを用いた2週間のダイアリー調査を、2020年1月に広島・熊本都市圏を対象として実施した。

表-3.1 SP調査の提示内容と選択肢

	PP調査より取得	行動を基にランダムに設定 (詳細は表-3.2)
提示内容	移動軌跡 エリア滞在時間 エリア通過時間	通行料金 時間帯別の料金 移動の短縮時間
行動の選択肢	1. 料金を支払い、今回と同じ移動をする 2. 移動を取りやめる 3. 時間帯を変える 4. 目的地を変更する 5. 交通手段を変更する 6. 経路を変更する	

表-3.2 仮想状況の設定詳細

行動の時間帯	1. 朝ピーク	6:00 - t	
	2. オフピーク	t - 16:00	
	3. タピーク	16:00 - 19:00	
	4. 課金対象外	19:00 - 6:00	
通行料金	エリア通過時間	プラン1 (円)	プラン2 (円)*
	1. 6:00 - t	Y	Z / 30 * Y
	2. t - 16:00	M*Y	Z / 30 * M * Y
	3. 16:00 - 19:00	Y	Z / 30 * Y
4. 19:00 - 6:00	0	0	
時間短縮	(Z * X) / 100分短縮		

Z: 課金エリア内の滞在時間 (分)  
 X: 10, 20, 30, 40,  
 Y: 50, 100, 250, 500, 1000,  
 M: 0.3, 0.4, 0.5,  
 t: 9:00, 10:00, 11:00  
 X, Y, M, t, はランダムに設定

### (3) 回答のタイミングが結果に及ぼす影響

上記の SP 調査においては、回答の時刻を記録しているため、回答遅れが回答の傾向に及ぼす影響を評価することができる。以下では、簡単なモデル構築を通じて、回答遅れの影響を定量的に評価する。具体的には、PP-SP 調査<sup>2)</sup>で取得したデータを用いて、仮想状況下における利用者の行動選択を説明するモデルを作成する。

表-3.1 に示す通り、本研究では、6 肢選択の問題を扱う。以下では、標準的な多項ロジットモデルを用いる。具体的には、各々選択肢の効用を以下のように定義する。

$$U_{ij} = V_{ij} + \varepsilon_{ij} \quad (3-1)$$

ここで  $V_{ij}$  は、個人  $i$  の選択肢  $j$  に対する確定効用であり、 $\varepsilon_{ij}$  は誤差項である。本調査方法では、RP の文脈を所与としたもって SP 調査を尋ねるため、誤差項に、SP と RP に対する影響が含まれる。

本研究では、(1)回答遅れを説明変数として追加することにより、回答遅れがもたらす系統バイアスを確認すること (仮説 1)、(2)SP, RP 属性それぞれに設定したスケールパラメータを回答遅れの関数とすることにより、回答遅れが RP 回答と SP 回答に及ぼす影響を定量的に把握すること (仮説 2、仮説 3) を達成するために、確定効用  $V_{ij}$  を以下のように定式化する。

$$V_{\{ij\}} = \theta_i^{SP} \beta_j^{SP} x_{ij}^{SP} + \theta_i^{RP} \beta_j^{RP} x_{ij}^{RP} + \gamma_j \ln(L_i) + \beta_j^{const} \quad (3-2)$$

ただし、 $x_{ij}^{SP}, x_{ij}^{RP}$  はそれぞれ SP 調査と RP 調査で得られた個人  $i$ 、選択肢  $j$  の説明変数、 $L_i$  は個人  $i$  の回

答遅れ[minutes]の対数値である。また、 $\beta_j^{SP}, \beta_j^{RP}$ は未知パラメータであり、 $\gamma_j$ は回答遅れに関する未知パラメータである。また、 $\theta_i^{SP}$ 及び $\theta_i^{RP}$ を以下のように定式化する。

$$\theta_i^{SP} = L_i^{\alpha_{SP}} \quad (3-3)$$

$$\theta_i^{RP} = L_i^{\alpha_{RP}} \quad (3-4)$$

ただし、 $\alpha_{SP}, \alpha_{RP}$ は未知パラメータである。

推定結果を表-3.3に示す。推定結果から得られる主な知見は以下の2点である。

第一に、回答遅れを表すパラメータ( $\gamma_j$ )が選択肢3(時間帯を変える)及び選択肢6(経路を変更する)において負で有意であることが確認された。また、有意ではないものの、選択肢2(移動を取りやめる)、選択肢5(交通手段を変更する)も負の値をとることから、利用者は回答遅れが大きくなるに従い、料金を支払いRPと同じ行動を選択する(行動変容しない)傾向があることが確認された。これは部分的に仮説1を支持する結果といえる。

第二に、SPデータとRPデータの影響を示す未知パラメータ $\alpha^{SP}$ が正の値、 $\alpha^{RP}$ が負の値となり、さらに双方のパラメータとも有意となった。回答遅れが大きくなるにつれ、SP属性に強く影響を受ける一方、RPの文脈要因の影響を考慮しない意思決定になることを示唆する結果といえる。以上の結果は、部分的に仮説2及び仮説3を支持する結果である。

表-3.3 MNL推定結果

Choice	2 移動 をとり やめる	3 時間 帯を変 える	4 目的 地を変 更する	5 交通手 段を変 更する	6 経路 を変更 する
	Estimate (t value)	Estimate (t value)	Estimate (t value)	Estimate (t value)	Estimate (t value)
定数項	-2.74 (-5.86**)	-1.08 (-5.48**)	-3.16 (-5.86**)	-2.04 (-6.86**)	-0.0986 (-0.67)
混雑課金 (円)	2.88E-03 (7.12**)	0.00275 (9.41**)	0.00259 (5.61**)	2.89E-03 (10.6**)	2.66E-03 (10.3**)
節約時間 (分)	-0.0242 (-0.94)	-0.0189 (-2.06*)	-0.00813 (-2.05*)	-0.0297 (-2.34*)	-0.0186 (-2.95**)
通勤ダミー	-1.56 (-1.48)	0.0299 (0.07)	-1.56 (-1.71+)	-0.0442 (-0.10)	7.76E-01 (2.95**)
業務ダミー	-2.03 (-2.41*)	-1.57 (-2.88**)	-1.36 (-1.14)	-0.859 (-1.85+)	-0.192 (-0.80)
送迎ダミー	-0.528 (-0.61)	-1.95 (-2.38*)	4.62E-01 (0.57)	7.77E-01 (1.66+)	-0.277 (-0.82)
年齢	9.37E-01 (1.76+)		9.23E-01 (1.62)		3.80E-01 (2.45*)
世帯年収 1000万円以 上ダミー		-1.97 (-2.56*)	1.44 (2.12*)		-0.622 (-2.89**)
6-9時回答 ダミー	-1.77 (-1.40)	-1.34 (-2.68*)	3.51E-01 (0.37)	4.39E-01 (1.04)	-0.322 (-1.26)
駅/バス停ま で200m以 内ダミー				3.64E-01 (1.41)	
$\gamma_j$	-0.0804 (-1.01)	-1.2E-01 (-3.21*)	7.59E-02 (0.93)	-0.0502 (-1.08)	-0.0685 (-2.65**)
$\alpha^{SP}$	7.04E-02 (2.38*)				
$\alpha^{RP}$	-1.04E-01 (-6.21**)				
$L(0)$	-2242.448				
$L(\beta)$	-3307.588				
Samples	1846				

2. 移動を取りやめる；3. 時間帯を変える；4. 目的地を変更する；  
5. 交通手段を変更する；6. 経路を変更する

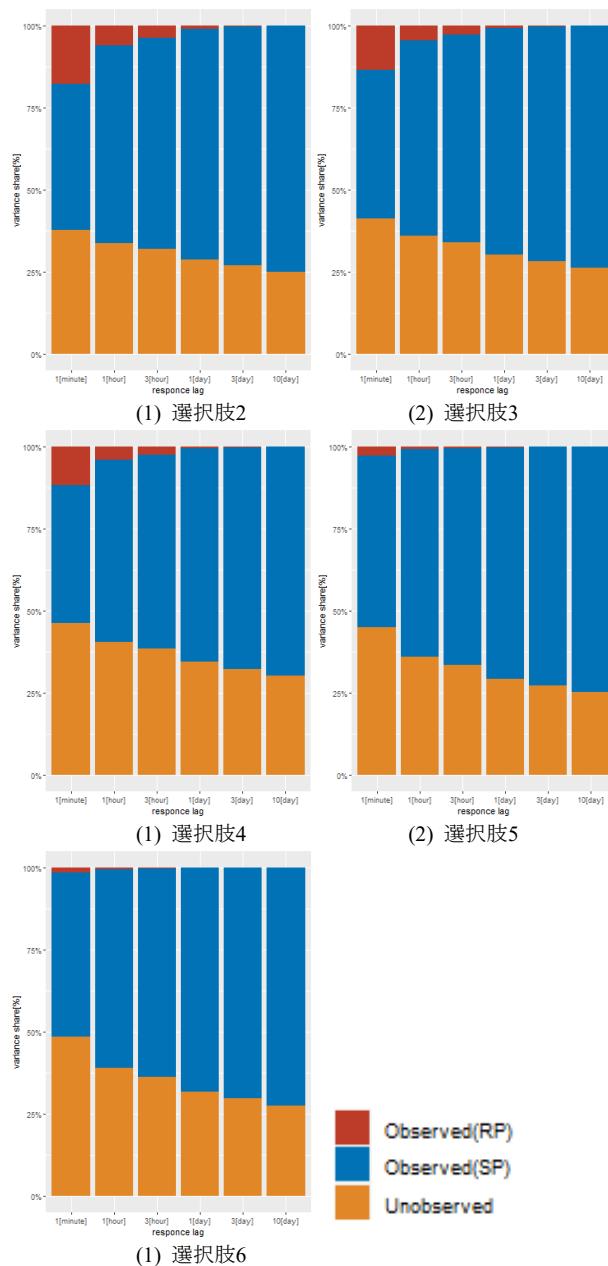


図-3.4 回答ラグ別の分散分解結果

さらに、回答遅れが誤差項(非観測要因)の影響に与える影響を可視化するために分散分解を行った(図-3.4)。図より、いずれの選択肢においても回答遅れが大きくなればなるほど、SP属性の影響が卓越するとともに、RPデータと誤差項の割合が減少した。誤差成分は非観測なRP属性を含むことを考慮すると、利用者の文脈を考慮した回答を行うには、回答のリアルタイム性が重要であることが実証的に示されたといえる。

#### (4) まとめ

本章では、リアルタイムで政策に対する選好情報を尋ねるreal-time context-aware 表明選好(SP)調査手法を開発し、回答遅れの影響が表明される選好に及ぼす影響を定量的に示した。混雑課金を対象に実施した分析の結果、リアルタイム性を有する選好抽出の技術を実装することの重要性が確認された。

### 3.3 Real-time context-aware表明選好(SP) 調査手法を用いた混雑課金の実証分析

#### (1) はじめに

本節では、前節にて開発したreal-time context-aware SP調査手法を用いて取得したデータを利用して、熊本市を事例とした実証分析を行う。(2)では、データの基礎集計を通して基本的な行動変容パターンを確認する。(3)では、選択モデル構築により、選択結果に及ぼす影響要因を定量的に確認するとともに、感度分析を行い、政策の影響を評価する。(4)では、混雑課金の空間異質性を確認するため、選択確率の可視化を行う。(5)にて研究成果を整理する。

#### (2) 基礎分析

調査によって取得されたトリップデータを表-3.4に示す。表中の「PP」および「SP」は、取得された全トリップのデータであり、削除トリップやSP設問に回答していないものも含む。そのうち、削除・無回答トリップを除外し、2つの調査を対応付けたものを「有効PP-SP」とした。本研究では「有効PP-SP」データのうち、熊本県内のみを移動した1,158トリップ(81人)を分析対象データとする。

本研究の分析対象者(81人)の個人属性を表-3.5に示す。年齢構成は41~50歳が最も多く、続いて31~40歳となっている。世帯人数は、2人以上の世帯が比較的多く、既婚者は全体の67.9%であった。世帯年収は、600万円以下の世帯が半分以上を占めている。

図-3.5は仮想的に提示された料金レベルと行動選択の割合を示している。これより、料金が100円以下の場合、48%の対象者が“同じ移動をする”と回答している。料金レベルが上がるにつれ、“同じ移動をする”の割合が減少し、他の5つの選択肢を回答した対象者の割合が増加している。料金が1000円を超えると、“移動を取りやめる”や“交通手段を変更する”といった自動車交通がなくなる選択肢の回答が増えると共に、“時間帯を変える”といった料金が安くなるような選択も増加している。

次に時間帯による通行料金の変化の影響を分析した。図-3.6にエリア行動時間帯の違いによる行動選択の割合を示す。これより、タピーク(16:00-19:00)に行動しているトリップは“料金を支払い、今回と同じ移動をする”の選択が若干減少傾向にあり、“時間帯を変える”“交通手段を変更する”の選択が増えている。要因として、課金時間帯外である19:00以降に行動を変えやすいことや朝・オフピークに比べ時間帯制約がないトリップが多いことなどが考えられる。

図-3.7に提示された移動短縮時間の違いによる行動選択の割合を示す。料金を支払うことによって短縮する時間が増えるほど“料金を支払い、今回と同じ移動をする”を選択するという仮説のもと確認を行ったが、大きな傾向は見られなかった。

表-3.6に、対象データの課金エリアへの流入入を示す。課金エリア内を出発地とし、エリア内を到着地とするトリップがおよそ半分を占めている。一方、

エリア外から出発し、エリアを通過したのちにエリア外に到着したトリップは全体の4.3%にとどまった。

図-3.8、図-3.9にトリップの出発地・到着地の違いによる行動変容を示す。表中の「エリア中心部」はエリア(ポリゴン)の中心から半径1.5km以内を出発・到着したトリップである。「エリア中心部」は、熊本城周辺を中心とし、大規模商業施設が立ち並ぶ通町筋や桜町バスターミナルなどの熊本都心部を含んでいる。“交通手段を変更する”を選択したトリップは、出発地・到着地がエリア中心部の場合多く、エリア外の場合は少ない傾向が見られた。これは、中心部では公共交通サービスが充実しており、自動車からの手段転換が生じやすいためと考えられる。一方、エリア外を出発したトリップは“目的地を変更する”を比較的多く選択しており、課金エリア内を通過しない目的地へ変更した可能性がある。

図-3.10にトリップ距離の違いによる行動変容を示す。短距離トリップでは、“移動を取りやめる”や“交通手段を変更する”の選択が多いのに対し、10km以上の場合、そのような傾向はみられない。短距離トリップの場合、自動車から徒歩やその他の交通手段への転換がしやすいなどの要因が考えられる。

次に公共交通機関へのアクセシビリティについての分析を行った。本研究では、アクセス距離およびイグレス距離をその指標とし、アクセス距離はトリップ出発地点からの最寄りバス停または駅までの距離、イグレス距離はトリップ到着地点からの最寄りバス停または駅までの距離と定義した。図-3.11、図-3.12にアクセス・イグレス距離の違いによる行動選択を示す。図よりアクセス・イグレス距離両方において、距離が近いほど“交通手段を変更する”を選択するのに対し、距離が300m以上になると選択が減っており、概ね妥当な結果となった。

表-3.4 取得トリップデータ

データ	人数	トリップ数
PP	97	4061
SP	83	1180
有効PP-SP	83	1162
分析対象データ	81	1158

表-3.5 分析対象者の個人属性

		N	(%)
性別	男性	44	54.3
	女性	37	45.7
年齢	21~30歳	11	13.6
	31~40歳	27	33.3
	41~50歳	31	38.3
	51~60歳	11	13.6
	61歳以上	1	1.2
世帯人数	1人	9	11.1
	2人	17	21.0
	3人	19	23.5
	4人	19	23.5
	5人	14	17.3
	6人以上	3	3.7
世帯年収	400万円以下	24	29.6
	401~600万円	25	30.9
	601~800万円	11	13.6
	801~1000万円	12	14.8
	1001万円以上	9	11.1




図-3.5 提示料金と行動選択




図-3.6 行動時間帯と行動選択




図-3.7 提示した短縮時間と行動選択




図-3.8 トリップ出発地と行動選択




図-3.9 トリップ到着地と行動選択




図-3.10 トリップ距離と行動選択




図-3.11 アクセス距離と行動選択




図-3.12 イグレス距離と行動選択

表-3.6 トリップの流入

移動形態	トリップ数 (%)
エリア内→内	557 (48.1%)
エリア内→外	279 (24.1%)
エリア外→内	272 (23.5%)
エリア外→外	50 (4.3%)
合計	1158 (100%)

(3) モデル分析

MNLモデルの推定結果を表-3.7に示す。

提示料金については、料金レベルが上がるほど“料金を支払い、今回と同じ移動をする”を選択しない傾向があることがわかった。

トリップ属性については、トリップの出発地がエリア外の場合“目的地を変更する”を選択する傾向にある。トリップの到着地が課金エリアの中心部の場合“料金を支払い、今回と同じ移動をする”“経路を変更する”を選択しない傾向がある。トリップ距離が長い場合、“移動を取りやめる”“交通手段を変更する”を選択しない傾向がある。公共交通へのアクセシビ

リティについては、アクセス距離が長い場合“交通手段を変更する”を選択しにくい傾向、イグレス距離が長い場合“目的地を変更する”を選択する傾向にある。トリップ目的については、時間制約トリップ（通勤・通学、業務）の場合“経路を変更する”を選択しやすい、買物トリップでは“料金を支払い、今回と同じ移動をする”“交通手段を変更する”“経路を変更する”を選択しにくい傾向がある。

個人属性については、年齢が上がるほど“料金を支払い、今回と同じ移動をする”“時間帯を変える”を選択しやすく、世帯年収が高いほど“交通手段を変更する”を選択しやすい傾向にある。単身世帯の場合“料金を支払い、同じ移動をする”を選択しやすく、“時間帯を変える”を選択しない傾向がある。表中に示した結果は、3章の基礎集計と同様の結果を示しており、概ね妥当な符号で有意になっているといえる。

NLモデルの推定結果を表-3.8に示す。表に示すツリー構造の場合、“料金を支払い、今回と同じ移動をする”と“移動を取りやめる”の2つの選択肢が独立で、それ以外の選択肢の類似性が高いという解釈ができ、比較的妥当な結果といえる。またログサムパラメータ( $\theta$ )は0~1の間に収まっておりツリーが成立している。MNLモデルと比較すると、モデルの適合度は若干ながらNLモデルの方が高い結果となった。説明変数のパラメータに関しては独立な2つの選択肢において、全個人で共通の効用値を意味する定数項のパラメータ値が小さくなっており、t値も有意な差が見られなかった。しかし、その他の説明変数のパラメータに大きな変化はなかった。

表-3.7 MNLモデル推定結果

選択肢	説明変数	パラメータ(t値)
同じ移動をする	定数項	2.86 (6.70 ***)
	提示料金 (円/100)	-0.36 (-8.76 ***)
	買物ダミー	-1.38 (-4.51 ***)
	年齢 (歳)	0.33 (4.29 ***)
	中心部到着ダミー	-0.84 (-3.72 ***)
	単身世帯ダミー	0.44 (1.95 **)
移動を取りやめる	定数項	1.40 (3.53 ***)
	トリップ距離 (km)	-0.94 (2.03 **)
時間帯を変える	定数項	0.85 (1.55)
	年齢 (歳)	0.29 (2.56 ***)
	単身世帯ダミー	-1.42 (-1.94)
目的地を変更する	エリア外出発ダミー	1.08 (3.01 ***)
	イグレス距離 (m)	0.28 (4.80 ***)
交通手段を変更する	定数項	2.88 (6.85 ***)
	アクセス距離 (m)	-0.34 (-2.31 **)
	トリップ距離 (km)	-1.50 (-4.35 ***)
	買物ダミー	-1.70 (-3.34 ***)
	世帯年収(万円)	0.083 (2.57 ***)
経路を変更する	定数項	3.34 (11.41 ***)
	アクセス距離 (m)	0.15 (3.22 ***)
	買物ダミー	-0.65 (-2.42 **)
	時間制約ダミー	0.57 (4.28 ***)
	中心部到着ダミー	-0.84 (-4.26 ***)
サンプル数	1158	
最終尤度	-1410.22	
修正済み $\rho^2$	0.3092	

表-3.8 NLモデル推定結果

選択肢	説明変数	パラメータ(t値)
同じ移動をする (1)	定数項	1.40 (1.35)
	提示料金 (円/100)	-0.36 (-8.77 ***)
	買物ダミー	-1.12 (-3.35 ***)
	年齢 (歳)	0.31 (3.92 ***)
	中心部到着ダミー	-0.66 (-2.78 ***)
	単身世帯ダミー	0.45 (2.05 **)
移動を取りやめる (2)	定数項	-0.04 (-0.04)
	トリップ距離 (km)	-0.97 (-2.09 **)
時間帯を変える (3)	定数項	0.83 (1.50)
	年齢 (歳)	0.31 (2.66 ***)
	単身世帯ダミー	-1.42 (-1.94)
目的地を変更する(4)	エリア外出発ダミー	1.08 (2.98 ***)
	イグレス距離 (m)	0.30 (4.66 ***)
交通手段を変更する(5)	定数項	2.91 (6.72 ***)
	アクセス距離 (m)	-0.34 (-2.18 **)
	トリップ距離 (km)	-1.42 (-4.06 ***)
	買物ダミー	-1.73 (-3.35 ***)
	世帯年収 (万円)	0.08 (2.46 **)
経路を変更する (6)	定数項	3.31 (10.77 ***)
	アクセス距離 (m)	0.20 (2.71 ***)
	買物ダミー	-0.64 (-2.25 **)
	時間制約ダミー	0.67 (3.99 ***)
	中心部到着ダミー	-0.89 (-4.28 ***)
ログサム	( $\theta$ )	0.61 (2.41 **)
サンプル数	1158	
最終尤度	-1409.4	
修正済み $\rho^2$	0.3093	
ツリー構造		

表-3.9 感度分析の属性値

	料金 (円)	アクセス距離
シナリオ1 (標準)	100	観測値
シナリオ2	200	観測値
シナリオ3	300	観測値
シナリオ4	100	30%減少
シナリオ5	100	50%減少

次に、MNLモデルおよびNLモデルのパラメータを用いて選択肢の選択確率を計算し、料金レベルやアクセス距離を変化させた場合の感度分析を行う。本研究では、アクセス距離を最寄りバス停もしくは駅までの距離と定義したが、ほとんどがバス停までの距離であった。既存研究より、バスの代表交通手段選択はイグレス距離よりもアクセス距離のほうが影響を及ぼすことが指摘されていることから、アクセス距離の選定に至った。表-3.9に感度分析に用いた属性値を示す。

(a) 料金レベルを変化した場合

図-3.13に料金レベルが変化した場合のNLモデルの選択確率を示す。料金が増加するにつれ“料金を支払い、今回と同じ移動をする”の確率は減少し、シナリオ1→3の間で14.9ポイント下がった。一方その他の5つの選択肢の確率は、料金が上がるにつれ増加する結果となった。

料金レベルごとの“料金を支払い、今回と同じ移動



をする”の選択確率から、課金収入を最大にする料金を計算したところ、360円の場合に課金収入が最大になるという結果になった。この際“時間帯を変える”は、課金時間帯外への変更とみなして計算している。

### (b) アクセス距離が変化した場合

公共交通機関での移動を促進するために、アクセス距離を減少した場合の感度分析を行う。図-3.14にアクセス距離が変化した場合のNLモデルの選択確率を示す。アクセス距離を観測値の50%減とした場合(シナリオ1→3)，“交通手段を変更する”の選択確率は2.0ポイントの増加にとどまった。このことから、ロードプライシング下での人々の行動は公共交通へのアクセシビリティよりも、料金が大きく影響していることがわかった。




図-3.13 料金レベルが変化した場合の選択確率 (NL)




図-3.14 アクセス距離が変化した場合の選択確率 (NL)

### (4) 選択確率の空間的可視化

ここではモデルにより計算できる選択確率を空間的に可視化し確率の空間的な分布を考察する。研究ではデータのサンプル数が少ないこと、点データが空間的に不規則に配置されていることなどを考慮してクリギング手法を用いた空間補間を行った。

図-3.15, 図-3.16はトリップ出発地および到着地における，“交通手段を変更する”の選択確率を空間的な分布にして表したものである。図中の赤点が鉄道駅、青線が平日のバス本数が60(本/日)以上のバス路線を示している。

出発地に関して、選択確率が高く分布しているのは課金エリアの中心付近であり、通町筋、桜町バスターミナルを含む中心市街地で確率が高くなっている。反対に課金エリアの外側(郊外)では公共交通の有無にかかわらず全体的に確率が低くなっており、鉄道駅やバス路線がない地域は特に低い傾向が出ている。この理由としては、出発地が中心市街地の場合は生活圏域が狭く、短距離トリップの場合は自動車から自転車・徒歩への切り替えがしやすい、長距離トリップの場合でも公共交通アクセスが発達しており多方面への移動が可能であるため、“交通手段を変更する”の選択確率が高くなったと考えられる。逆に出発地が郊外の場合は生活圏域が広いことに加え、公共交通でアクセスが可能な地域は限られているため、選択確率が低くなったと考えられる。

到着地に関して、“交通手段を変更する”の選択確率が高く分布している地域は、中心市街地だけでなく鉄道駅やバス路線が周辺にある郊外部にまで広がっている。選択確率が低い地域としては、鉄道駅、バス路線が周辺にない郊外部で顕著に低い傾向が出ている。このことから、中心市街地付近から出発したトリップが各方面に散らばったことで、到着地における選択確率の分布が広がったことがわかる。

また、公共交通のアクセス・イグレス距離以外の影響として世帯年収といった個人属性が挙げられる。集計分析から、世帯年収が高いほど“交通手段を変更する”を選択する傾向があることを確認している。この原因として、中心市街地付近のトリップ出発地は高年収の割合が高く、高年収の場合中心市街地付近に、低年収の場合郊外に出発地が集中している傾向が考えられる。よって高収入の場合“交通手段を変更する”を選択しやすいのに対して、低収入の場合は選択しにくかったことが窺える。

### (5) おわりに

本研究では、ロードプライシングを想定したPP-SP調査を利用し、行動モデルを用いて行動選択に関する分析を行い、政策が行動変化に与える影響を明らかにした。また、推定したモデルを用いて感度分析を行い、行動選択の支配的な要因を分析し、得られた選択確率を空間的に可視化した。本研究より得られた成果を以下にまとめる。

1) 提示料金において料金レベルが上がるほど“料金を支払い、今回と同じ移動をする”の選択が

減

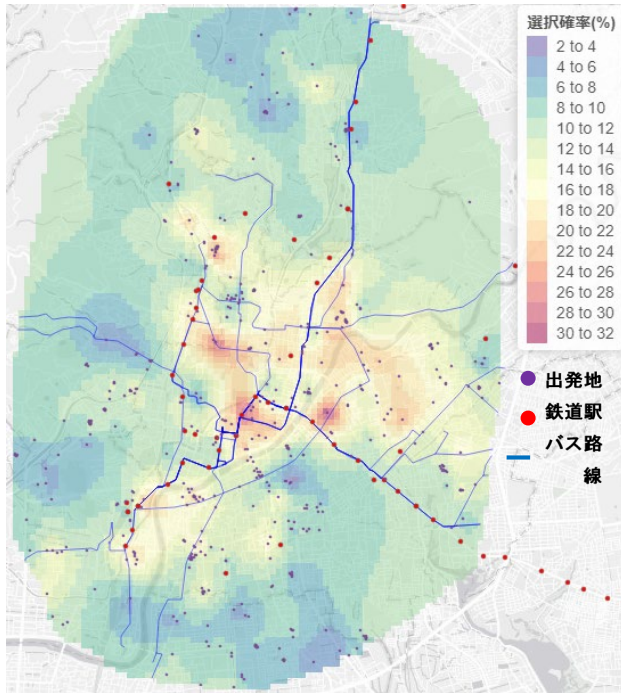


図-3.15 “交通手段を変更する”の空間的分布（出発地）

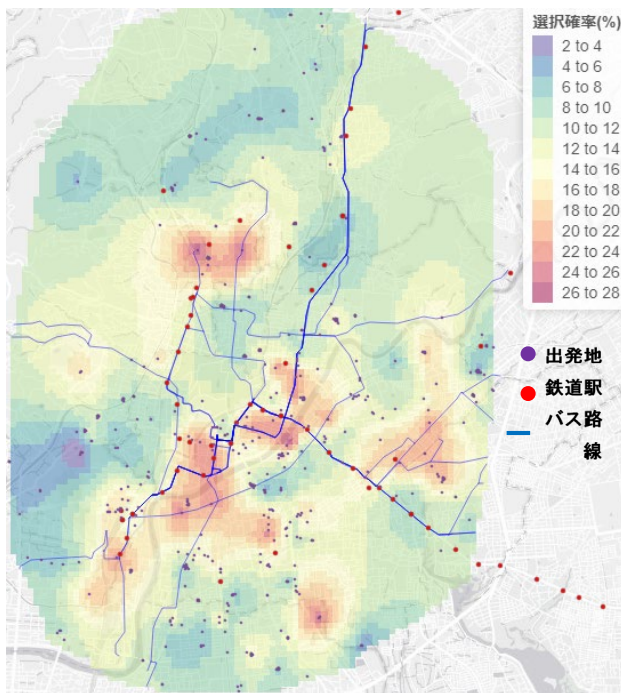


図-3.16 “交通手段を変更する”の空間的分布（到着地）

り、“時間帯を変える”や“交通手段を変更する”“移動を取りやめる”といった選択が増える傾向にあった。

- 課金による移動の短縮時間については、短縮時間の変化による行動選択の変化は見られず行動への影響がないといえる。
- 基礎分析・行動モデルの推定結果から、ロードプライシング下での行動選択に影響を与える要因として、料金レベル、トリップ属性（OD、目的、トリップ距離、アクセス・イグレス距離）、個人属性（年齢、世帯年収、世帯人数）が影響するこ

とが示された。

- 感度分析の結果から、公共交通へのアクセシビリティよりも料金レベルが行動選択の支配的な要因であることがわかった。
- “交通手段を変更する”の選択確率を空間的に可視化すると、出発地が中心市街地付近の場合に高く、郊外の場合低い傾向がみられ、交通アクセスや世帯年収の違いによる行動パターンの変化などが要因として挙げられる。

### 3.4 インセンティブ生成アルゴリズムの提案

#### (1) はじめに

交通マネジメント（TDM）戦略は、大きく分けて3つのカテゴリーに分けられる。a) 混雑時の価格設定、駐車場料金、公共交通機関への補助金などの政策を含むコストまたは価格ベース、b) 道路の削減や制限、ボトルネック通行権取引やトラベルクレジットなどの政策を含む供給または数量ベース、c) ライドマッチングのための両面市場の創出、持続可能な旅行決定を促進するためのインセンティブの提供、情報提供、利用者への教育等の取り組みを含む支援的な戦略である。これらの戦略は、文献の中では様々な程度の注目を集めている。また、情報通信技術（ICT）の発展により、これらの戦略の効果的な実施が容易になった。

コストベースまたは価格ベースの戦略は、実世界での適用例が多く、おそらく最大の注目を集めている<sup>5),6)</sup>。これは通常、利用者が道路を利用するために支払う価格を指し、そのような戦略の公平性の恩恵を取り上げた理論的研究とシミュレーションを含む経験的研究の両方が存在する<sup>7)</sup>。しかし、価格ベースの戦略の限界は、道路利用者がそれを別の追加コストや「税」と考えていること<sup>5)</sup>や、交通状況が空間や時間帯によって異なるため、時空間的な一般化が難しいことに関連している。近年、需要の時空間変動の問題に対処しようとする動的料金実装に向けた理論的努力が多くなされている<sup>8),9)</sup>。

一方、供給または数量ベースのTDM戦略は、道路インフラの利用制限や規制に焦点を当てている。これらの戦略には、交通システムのための専用レーンとしての道路制限<sup>10)</sup>、ナンバープレートに基づく制限等の道路空間の制限<sup>11)</sup>、駐車場制限（Marsden, 2006）等がある。近年注目されているベースの戦略には、ボトルネック通行権取引<sup>12),13)</sup>、Tradable credits<sup>14),15)</sup>等が挙げられる。これらの戦略では、システムの容量に相当する限定的な通行権やクレジットを利用者の移動に割り当てる仕組みを設計している。価格ベースの戦略とは異なり、数量ベースの戦略では利用者の需要選好を観察する必要がない。また、メカニズム設計では、社会財の戦略性や効率的な資源配分の考え方に依存している<sup>16)</sup>。しかし、このような戦略の大きな限界は、そのシステムに外生的な外部性に対応できないことに関連している。例えば、非自動車利用者のようなシステム外の利用者に関連する外

部性は、このような取引可能なクレジットに基づくTDM戦略では対応できない。また、多くの枠組みにおいて供給が固定であることを前提としたTDM戦略が議論されており、配車サービスのような供給に対しても介入できるケースを想定できていない。

価格ベースの戦略と数量ベースの戦略の両方が理論的な基礎を提供しているとはいえ、これらの戦略を実世界の状況に適用するためには、さらなる研究が必要な側面が多くある。一方、二面的（または多面的）な市場のマッチングやインセンティブに基づくTDM戦略のような支援戦略は、実世界の状況での実施が比較的容易であるため、利用者と政策立案者の双方に受け入れられやすいと考えられている<sup>9)</sup>。Budish (2012)<sup>17)</sup>は、マッチング設計とメカニズム設計の関係性とトレードオフを比較し、学校選択のような単純な選択に対しては、効率性や公平性など様々な「良い特性」を満たすマッチング設計の方が、伝統的に社会福祉等の設計者の変数の最適化を伴うメカニズム設計よりも優れたパフォーマンスを発揮すると結論付けている。また、どちらの方法にも長所と短所があるとコメントしている。一方、インセンティブに基づく戦略の適用は、研究者の間で関心が高まっている。インセンティブを提供する様々なスキームが、現金、ポイントベース、抽選ベース、スタティック、パーソナライズされたリアルタイムインセンティブの適用を含む研究で検証されてきた<sup>9)</sup>。

Zhu et al. (2020)<sup>18)</sup>は、個人の選好を把握し、選好に基づいた選択肢を提供することで、パーソナライズされたインセンティブを付与するシステムを開発している。彼らは、報酬ポイントベースのシステムに基づいてインセンティブを予測、測定、更新するための三段階のフレームワークを開発した。基本的に、報酬ポイントは後になって交通機関のパスの割引のようなものと交換することができる。全ての予測状態は、利用者に促進された代替手段（彼らの研究では出発時刻選択）を選択するためのインセンティブを提供し、これらのインセンティブは前回の選択に基づいて決定される。測定段階では、利用者は「通常の出発時刻」と「代替出発時刻」の二つの選択肢を提示され、利用者の選好が測定される。最後に、更新段階では、以前に選択した選択肢に基づいて選好推定値が更新され、次の予測段階の入力情報として活用される。彼らの研究では、新しい出発時刻の受け入れ率は68%であり、これにより交通時間が48%短縮されると推定されている。一方、Azevedo et al. (2018)<sup>9)</sup>は、出発時刻選択、経路選択、交通手段選択、ライドシェア、運転スタイル等、様々な選択変数にわたって持続可能な選択をするためのポイントベースのパーソナライズされたインセンティブを利用者に提供することで、ネットワーク全体のエネルギー節約を最大化する「Tripod」と呼ばれるネットワーク全体のリアルタイムパーソナライズされたインセンティブシステムを開発している。パーソナライズされたインセンティブをリアルタイムで提供するには、大規模なデータセットの分析、利用者の長期

的な追跡が必要であるため、このようなスキームは金銭的にも計算コストの観点でも高くなる。

本研究では、利用者の過去の選択と選好を考慮し、持続可能な旅行選択を促すためのインセンティブを提示するパーソナライズされたインセンティブスキームを開発する。本研究のアプローチが他の研究と異なる主な特徴は以下の通りである。

- 1) 静的ではあるがパーソナライズされたインセンティブスキームを提案し、過去の選択に基づいたインセンティブを利用者に提示している。本研究では、広島で実施されたPP調査から収集した情報を用いて、人々の選好を知り、過去の行動に基づいてインセンティブを生成している。また、前回調査の参加者の一部は、新規調査に再度参加し、インセンティブを付与した。そのため、緩い仮定のもとでインセンティブ付与の効果を実証的に計測可能である。
- 2) 本研究では、自家用車から公共交通機関や内燃機関によらない交通手段へのモーダルシフトに着目する。最適化問題の目的関数は、自動車や二輪車などの自家用車の確率を最小化することである。自家用車の利用を最小化するための最適なインセンティブを導出し、それをもとに介入実験を実施した。
- 3) 利用者には、一定の予算を設定して、直接的な金銭的便益を提供することで、現実の条件に近い形で介入実験を行っている。
- 4) 金銭的なインセンティブとは別にレコメンデーション情報を提供し、その影響が評価可能な形で介入実験をデザインした。また、環境に優しい交通手段（バス、電車、徒歩、自転車）や健康に良い交通手段（徒歩、自転車）を選択した場合に追加のインセンティブが付与されるケースについても併せて検討した。

## (2) インセンティブ生成手順

インセンティブの設計手順の概要は以下の通りである。

**手順1:** パネル混合ロジット型の交通手段選択モデルを推定し、個人毎の時間価値を推定する。

**手順2:** 個人毎の時間価値に応じて、動的交通手段の利用を最小化するように、予算等一連の制約条件のもとで、各交通手段の利用に対してインセンティブを決める最適化問題を解く。

以下では、次節にて述べる介入実験において使用したインセンティブ生成手順を概説する。なお、制約条件を変更する（例えば予算額を変更する）、目的関数を変更する（例えば動的交通手段選択確率の最小化ではなく、消費者余剰の最大化を目指す）等の変更は容易にできるW。

介入実験のデザインにおいては、まず、2019年度に収集したPP調査データ（3.2節参照）を利用し、パネル混合ロジット型の交通手段選択モデルを推定した（手順1）。表-3.10にパネル混合ロジットモデルの推定結果を示す。交通コスト変数の平均パラメータ

値は-0.022であり、標準偏差は0.019で個人ごとに変化することが確認された。一方、交通時間短縮価値は、2.239円/分から54.213円/分、平均28.220円/分（標準偏差=14.12）であった。交通時間短縮価値が高い個人ほど、私的動力交通からの手段転換に高いインセンティブが必要と予想される。そのため、利用者の交通時間短縮価値のばらつきを考慮した個人別インセンティブ表を作成する。

次に、推計した個人毎の交通時間短縮価値を利用し、以下の最適問題を構成した。

$$\text{minimize } z = (P_{i,car} + P_{i,motorcycle})$$

Subject to:

$$\begin{aligned} \sum_j incentive_j &= congestion_{adj} * Total\ amount \\ 0 \leq incentive_{bicycle} &\leq congestion_{adj} * Total\ amount + val\_1_{adj} \\ 0 \leq incentive_{bus} &\leq congestion_{adj} * Total\ amount + val\_1_{adj} \\ -500 \leq incentive_{car} &\leq -(congestion_{adj} * Total\ amount + val\_2_{adj}) \\ -500 \leq incentive_{motorcycle} &\leq -(congestion_{adj} * Total\ amount + val\_2_{adj}) \\ 0 \leq incentive_{public\ transport} &\leq congestion_{adj} * Total\ amount + val\_1_{adj} \\ 0 \leq incentive_{walk} &\leq congestion_{adj} * Total\ amount + val\_1_{adj} \end{aligned}$$

ここで、 $P_{i,car}$ 、 $P_{i,motorcycle}$ は自動車、二輪車それぞれを選択する確率。具体的には、推定したパラメータを所与として効用の確定項を、 $V_{i,j} = asc_j + \beta_{tc,i} * \{VTT_i * travel\ time_j + (travel\ cost_j - incentive_j)\}$ とし、 $P_{i,j} = \exp(V_{i,j}) / \sum_{j \in J} \exp(V_{i,j})$ により求める。なお、 $asc_j$ は混合ロジットモデルから算出される交通手段jの選択肢固有定数項、 $\beta_{tc,i}$ は混合ロジットモデルから算出される利用者iのコストパラメータ、 $VTT_i$ は混合ロジットモデルから算出される利用者iの交通時間短縮価値、 $travel\ time_j$ は交通手段jの旅行時間、 $travel\ cost_j$ は交通手段jの交通費用、 $incentive_j$ は交通手段jを選択することで得られるインセンティブである。また、 $congestion_{adj}$ :時間帯に基づく混雑水準の調整パラメータであり、介入実験では0.4から1.0の間で変化させる（詳細は後述する）。 $Total\ amount$ は、予算制約であり、介入実験では0、125、250円の値からランダムに選択する。 $val\_1_{adj}$ 、 $val\_2_{adj}$ は、不等式制約の上限値（100円もしくは200円）であり、最適化の際に極端なインセンティブが付与されないように追加している。

表-3.10 交通手段選択モデル推定結果

変数	パラメータ	標準誤差	t値
選択肢固有定数項 (自転車)	2.409	0.170	14.15
選択肢固有定数項 (バス)	1.122	0.085	13.26
選択肢固有定数項 (自動車)	2.071	0.155	13.39
選択肢固有定数項 (二輪車)	2.150	0.167	12.91
選択肢固有定数項 (電車)	0.095	0.107	0.89
交通時間短縮価値 mu	3.143	0.038	83.89
交通時間短縮価値 sigma	0.924	0.017	55.14
交通コスト mu	-1.934	0.172	-11.28
交通コスト sigma	-5.687	0.266	-21.35
対数尤度(0)	-44845.3		
対数尤度(final)	-14952.7		
決定係数	0.667		
自由度修正済決定係数	0.666		
赤池情報量基準	29923.44		
交通時間短縮価値 平均 (円/分)	28.220		
交通時間短縮価値 標準偏差(円/分)	14.116		
交通コスト ベータ平均	-0.022		
交通コスト ベータ標準偏差	0.019		

### (3) おわりに

本研究では、パーソナライズされたインセンティブを生成するアルゴリズムを提案した。しかしながら、このようなインセンティブ付与に基づく交通マネジメントが有効となるためには、採用した行動モデルが実際の人々の選択行動を再現できている場合に限られる。次節では、以上に述べたインセンティブ生成手順に基づき実施した介入実験結果を報告し、今後の課題を整理する。

## 3.5 インセンティブ及びレコメンデーションに着目した介入実験

### (1) はじめに

本節では、3.2節の混雑課金SP調査の際に対象とした広島市都心部のエリア（図-3.2(a)）を対象に、被験者へのインセンティブ及びレコメンデーション情報提供機能を付加した介入実験を実施した結果を報告する。(2)では、介入実験の設計について概説する。(3)では基礎的な実験結果を、(4)ではインセンティブ付与による行動変容結果について報告する。(5)にて研究成果及び今後の課題を整理する。

### (2) 介入実験の設計

本介入実験は、広島市の郊外から対象エリア（都心部）への自動車利用者をターゲットに実施した。2019年度のPP調査データよりインセンティブを算出するため、2019年度の混雑課金調査（32.節参照）の被験者を優先的に募った。

介入実験期間は14日間であり、期間中、前日の18:00にアプリのプッシュ通知機能を用いて介入情報（インセンティブ+レコメンデーション）を提供した。また、プッシュ通知から遷移するwebアンケートページにインセンティブ表を掲載した。レコメンデーション及びインセンティブ表のスクリーンショットを図-3.17に示す。

介入実験では、インセンティブを増減させることによる行動変容を確認するため、表-3.11に示す属性の水準を調査日毎にランダムに変更し、当該日の水準を所与として最適化問題を解き、当該水準のもとでの最適インセンティブを提示した。なお、最適化問題は個人毎に解く必要があり、計算負荷が高いため、本研究では、2019年度のデータから構築した交通手段選択モデル（表-3.10）から事前に各個人毎に14日間分の最適インセンティブを出力することで対応した。2019年度の調査に参加していない新規の被験者については、昨年度の被験者に対して生成したインセンティブ表からランダムにピックアップし介入実験時に提示した。レコメンデーションの内容は、図-3.18に示す通りであり、表-3.11の属性水準で情報提供ありとなった場合にのみ提示した。また、表-3.11内の「混雑調整」については、表-3.12に示す通りに設定した。



図-3.17 介入情報例

今日のメッセージ： あなたが排出する CO2（地球温暖化ガス）の約 25%は車の利用に起因します。車の利用を控えましょう。 ※明日は環境負荷の抑制を促進する日です！ 徒歩・自転車・公共交通を利用された方に 50 円/回の謝礼を追加しています。
今日のメッセージ： 徒歩や自転車での移動は、健康増進に役立ちます。積極的に歩いたり自転車で移動しましょう。あなたが排出する CO2（地球温暖化ガス）の約 25%は車の利用に起因します。車の利用を控えましょう。 ※明日は環境負荷の抑制・健康増進を促進する日です！ 公共交通を利用された方に 50 円/回、徒歩・自転車を利用された方に 100 円/回の謝礼を追加しています。
今日のメッセージ： 徒歩や自転車での移動は、健康増進に役立ちます。積極的に歩いたり自転車で移動しましょう。 ※明日は健康増進を促進する日です！ 徒歩・自転車を利用された方に 50 円/回の謝礼を追加しています。

図-3.18 レコメンドーション情報例  
(追加インセンティブが付与される場合)

表-3.11 インセンティブ設計で考慮した属性

属性	水準	説明
予算制約	満額	インセンティブの合計は 250 (円/人/トリップ)
	半額	インセンティブの合計は 125 (円/人/トリップ)
	ゼロ	インセンティブの合計は 0 (円/人/トリップ)
混雑調整	スロープ	インセンティブは時間帯やその後の混雑度に応じて変化する。
	バイナリー	インセンティブは渋滞ピーク時と非ピーク時の 2 つの異なる時間帯に基づいて異なる。
	同じ	インセンティブは時間帯に依存しない。
健康に対するインセンティブ	イエス	徒歩、自転車の交通手段に追加の 50 円が付与される。
	ノー	追加のインセンティブなし。
	イエス (情報あり)	徒歩、自転車の交通手段に追加の 50 円が付与される。加えて、インセンティブ付与に関するメッセージが提示される。
環境に対するインセンティブ	イエス	徒歩、自転車、バス、公共交通機関の交通手段に追加の 50 円が付与される。
	ノー	追加のインセンティブなし。
	イエス (情報あり)	徒歩、自転車、バス、公共交通機関の交通手段に追加の 50 円が付与される。加えて、インセンティブ付与に関するメッセージが提示される。
レコメンドーション	健康	健康効果の情報提供。
	環境	環境効果の情報提供。
	両方	健康、環境効果の両方の情報提供。
	なし	情報提供なし

表-3.12 混雑調整パラメータの設定

	時間帯	段階的	バイナリー	同じ
1	00:00:00-05:59:59	0.4	0.4	0.7
2	6:00:00-6:29:59	0.4	1.0	0.7
3	6:30:00-6:59:59	0.5	1.0	0.7
4	7:00:00-7:29:59	0.8	1.0	0.7
5	7:30:00-7:59:59	1.0	1.0	0.7
6	8:00:00-8:29:59	0.9	1.0	0.7
7	8:30:00-8:59:59	0.7	1.0	0.7
8	9:00:00-9:29:59	0.7	1.0	0.7
9	9:30:00-9:59:59	0.7	1.0	0.7
10	10:00:00-15:59:59	0.4	0.4	0.7
11	16:00:00-16:29:59	0.7	1.0	0.7
12	16:30:00-16:59:59	0.6	1.0	0.7
13	17:00:00-17:29:59	1.0	1.0	0.7
14	17:30:00-17:59:59	0.8	1.0	0.7
15	18:00:00-18:29:59	0.8	1.0	0.7
16	18:30:00-18:59:59	0.6	1.0	0.7
17	19:00:00-19:29:59	0.6	1.0	0.7
18	19:30:00-19:59:59	0.5	1.0	0.7
19	20:00:00-23:59:59	0.4	0.4	0.7

調査は、令和2年10月26日（月）～令和2年11月8日（日）、及び、令和2年11月2日（月）～令和2年11月15日（日）の2期間に分けて実施した。両期間を通じて調査を依頼した人数は243人、最終的な有効回答数（モニターの該当調査期間でGPSをつけた状態での調査実施日が3日以上確認できた人数）は154人であった。

### (3) 実験結果の概要

インセンティブ付与の対象となるトリップは、図-3.2(a)に示す対象エリアに外から流入する移動、対象エリアから出発している移動である。インセンティブ付与対象トリップの内訳を確認すると外→内トリップが619トリップ、内→内トリップが509トリップ、内→外トリップが640トリップであった。

図-3.19～図-3.22に対象トリップの交通手段及びトリップ目的を示す。路面電車沿いを除き、車を利用したトリップが多いこと、業務または通勤通学目的のトリップが多いことが確認できる。

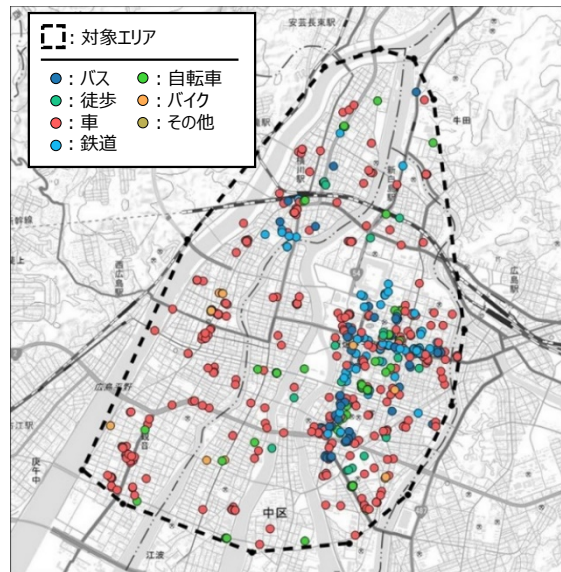


図-3.19 トリップの交通手段（外→内）

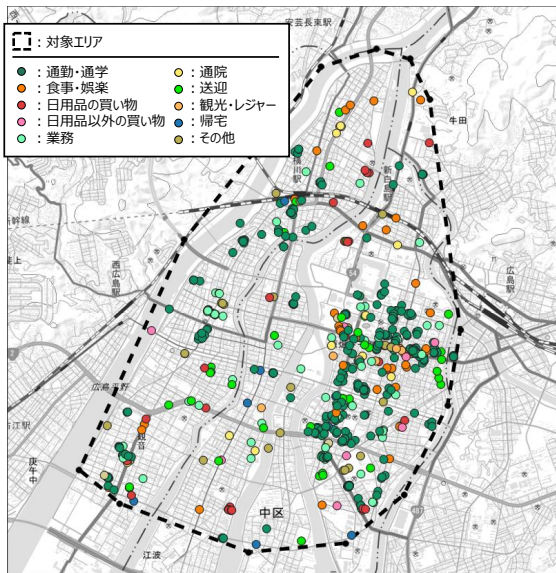


図-3.20 トリップの活用目的 (外→内)

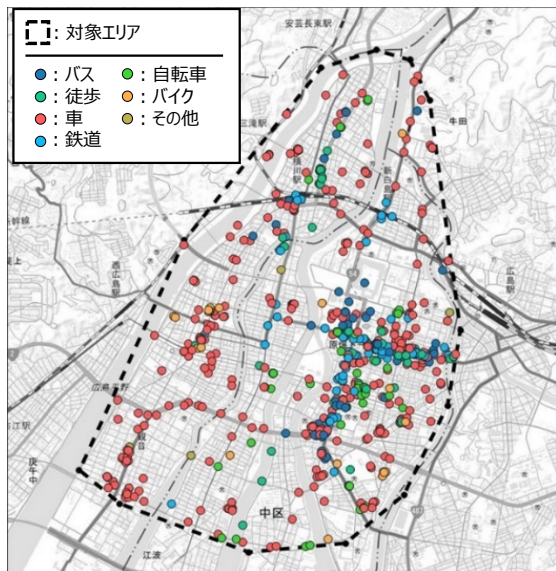


図-3.21 トリップの交通手段 (内→外)

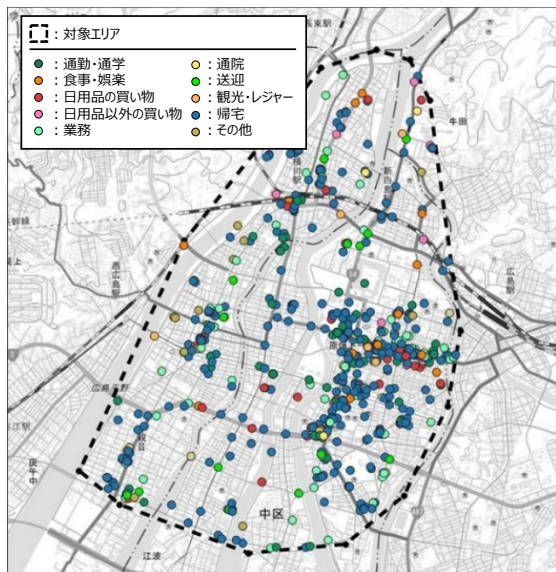


図-3.22 トリップの活用目的 (外→内)

#### (4) インセンティブによる行動変容

図-3.23は被験者に提示したインセンティブ値の分布を示している。自動車と二輪車については、値がゼロ以下かゼロになるように制約されている(前節参照)。一方、自転車及び二輪車のインセンティブがゼロになる頻度が高いのは、回答者の多くがこれらの交通手段を利用できないためである。また、自動車を選択する際のペナルティの平均値は、-160.6円となっている。一方、二輪車、自転車、バス、電車、徒歩を選択した場合の平均インセンティブは、それぞれ-5.8円、14.29円、116.8円、116.8円、150.7円となっている。

再度調査に参加した参加者(n=28)のうち、自動車の利用率は初回調査の80%から75.9%に減少していることが示された(表-3.13)。一方、二輪車の利用率は5.8%から9.1%に増加している。自動車以外では、自転車やバスの利用が増加しているが、電車や徒歩の利用は減少していることが確認された。

表-3.14に、2019年度、2020年度双方の調査に参加した28人の自動車利用の変化を示す。自動車利用の割合が減少しているのは、28人中6人のみであることが確認された。一方、28人中13人では変化が確認されなかった。残りの9人では、前回調査に比べて自動車利用が増加する結果となった。インセンティブ値で比較すると、平均的なインセンティブ値が300から400円と低から中程度の範囲にある利用者では、その割合が減少していることが見てとれる。一方、平均的なインセンティブ値が高い(400円以上、または200円以上の自動車のペナルティ)参加者では、自動車利用の割合に変化は見られないか、増加していることが確認された。これは、平均的にインセンティブやペナルティが高かった利用者は、ピーク時の混雑時間帯に移動することが多く、その時間帯に自動車を利用していたということが考えられる。また、2019年度の調査では、これらのグループは既に自動車への依存度が高かったことにも言及しておく必要があるが、総じて、2019年度の行動データから作成したモデルでインセンティブを付与したところ、期待していた行動変容はほとんど生じなかったと結論付けざるを得ない。この原因として、トリップチェーンを考慮した行動モデルを採用せずにインセンティブを計算した点、時間価値を時間帯別に計算できていない点等が挙げられる。また、別のアプローチとして、ある行動メカニズムを前提にインセンティブを設計するのではなく、達成したい状態(例えば自動車の分担率)を設定するまで、逐次的にインセンティブを変更するような交通マネジメントの設計もあり得る。いずれにしても、モデル構造の正しさを前提に最適なインセンティブを計算することに対し、一定の注意が必要である点が本介入実験を通じて得られた重要な結論と考える。

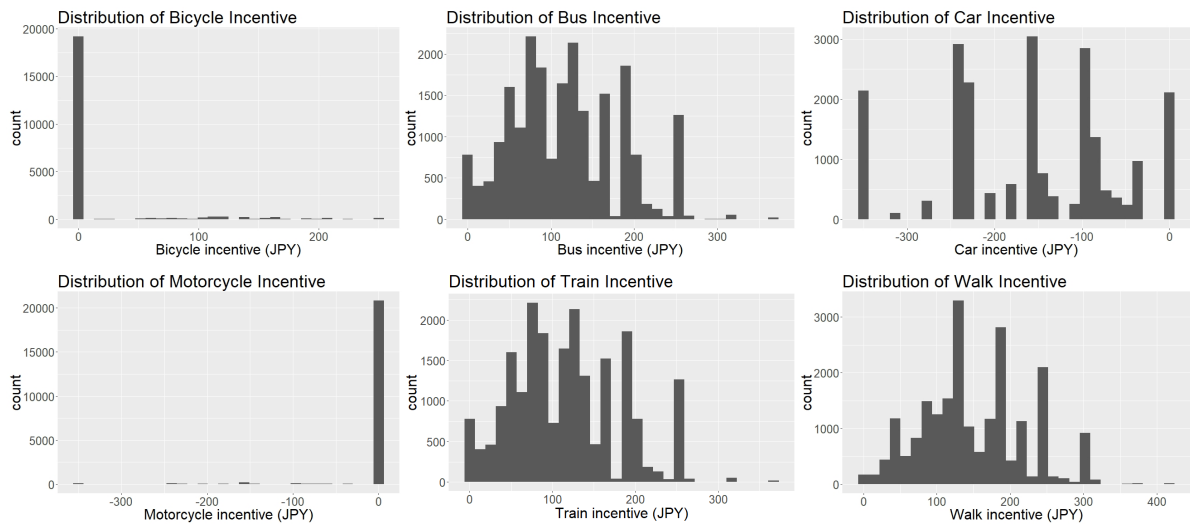


図-3.23 提示されたインセンティブの分布

表-3.13 交通手段選択割合

交通手段	交通手段選択割合	
	事前調査 (2019年調査)	事後調査 (2020年調査)
自転車	2.7	5.4
バス	1.7	6.2
自動車	80.0	75.9
二輪車	5.8	9.1
電車	1.7	1.0
徒歩	8.2	2.3
合計人数	28	28
合計トリップ数	396	386

表-3.14 提示されたインセンティブ値と自動車利用割合の変化（対象エリアを目的地とするトリップのみ）

利用者	私的動力交通以外の交通手段に対するインセンティブの平均値	私的動力交通に対するインセンティブの平均値	事前調査トリップ数 (自動車シェア%) → 事後調査トリップ数 (自動車シェア%)
1	327.71	-111.86	19 (89.5) → 7 (28.6)
2	382.38	-134.63	14 (71.4) → 24 (29.2)
3	364.88	-171.81	25 (60) → 16 (25)
4	338.60	-116.60	3 (33.3) → 5 (0)
5	297.75	-103.75	2 (50) → 4 (25)
6	312.89	-113.56	11 (90.9) → 9 (77.8)
7	387.75	-155.31	30 (100) → 17 (100)
8	396.00	-158.00	44 (100) → 23 (100)
9	510.13	-219.50	22 (100) → 16 (100)
10	339.39	-138.24	7 (100) → 2 (100)
11	452.64	-183.86	6 (100) → 8 (100)
12	329.50	-134.25	40 (100) → 70 (100)
13	432.00	-161.00	17 (100) → 14 (100)
14	464.13	-235.22	10 (100) → 8 (100)
15	452.50	-183.75	1 (100) → 3 (100)
16	575.10	-240.00	2 (0) → 4 (0)
17	284.30	-87.67	8 (100) → 10 (100)
18	341.35	-168.76	21 (100) → 27 (100)
19	221.94	-61.47	12 (100) → 17 (100)
20	258.39	-98.67	19 (94.7) → 18 (100)
21	447.40	-116.30	27 (59.3) → 10 (70)
22	463.54	-203.46	19 (78.9) → 13 (92.3)
23	569.67	-186.67	3 (66.7) → 3 (100)
24	419.31	-180.94	12 (66.7) → 16 (100)
25	419.20	-171.60	5 (60) → 5 (100)
26	460.05	-196.70	10 (20) → 20 (75)
27	413.85	-173.54	4 (25) → 13 (92.3)
28	298.00	-141.25	2 (0) → 4 (100)

### (5) おわりに

本節では、前節にて提案したパーソナライズされたインセンティブ付与の有効性を確認するための介入実験を実施した。今回の調査で収集したデータを予備的に分析した結果、平均的には自動車利用の割合の減少が確認されたものの、利用者ごとの平均値を比較すると、本調査に参加した28人のうち、自家用車利用の減少が確認されたのは6人のみであった。このことは、モデル構造の正しさを前提に最適なインセンティブを計算することに対し、一定の注意が必要であることを示唆する。モデル構造の改善、または、インセンティブ付与の背後に行動メカニズムを想定しない、データドリブンなインセンティブ付与の方法との比較検証を行う等を今後実施する必要がある。

### 3.6 ICTが生活・交通行動に及ぼす影響を包括的に捉える調査の設計・実施

#### (1) はじめに

近年、UberやGrab、GOJEKといったスマートフォンアプリを通じて配車サービスを提供する企業は、そのサービスを多様化させている。例えば食事や薬、日用品の買物代行を依頼し自宅に届けてもらうサービスや、マッサージ師に自宅に来てもらうサービスなど、登録ドライバーを多く抱える配車アプリならではのサービス展開が進んでいる。本章では、これらの配車サービスをベースに多様化するサービスを提供するプラットフォームを、multi-service transport platform (MSTPs)と呼称する。現時点では我が国においては広く普及しているわけではないものの、後述するように、インドネシアをはじめとした幾つかの国においては、これらのサービスが広く利用され、交通行動・生活行動パターンを大きく変えつつある。さらには、レストランの立地や形態の変化（利用者に来てもらう形態から配車サービスを利用したデリバリーサービス中心の形態への移行）など、土地利用にまで影響を及ぼしつつある。今後、我が国でも

類似のサービスが普及する可能性が高いことから、本章では、以上にみた配車サービスが生活・交通行動に及ぼす影響を確認することを目的に、インドネシア・ジャカルタ市を対象としたPP-SP調査を設計・開発し、実施した。

## (2) 調査設計

本研究では、計300人のMSTPs利用者を対象に、スマートフォンアプリを利用した2週間の交通日誌調査を実施した（有効被験者数225人）。スマートフォンアプリは、Mobile Market Monitor (MMM)社のアプリ（図-3.24参照）を改修して利用する。改修した点は、主に(1) すべての活動実施後に活動期間中のICT利用実態の設問を追加、(2) GOJEKやOJEK等、インドネシア特有の交通手段の追加、(3) 買い物及び外食の場合、その活動内容、消費金額等の詳細を尋ねる設問の追加、の3点である。

調査は、2020年1月28日～2月12日に実施した。住宅地または就業地が南ジャカルタ（図-3.25）にある人々に対して調査を実施した。南ジャカルタは、インドネシアの政府機能が集中するエリアであり、MSTPsサービスの水準が高いエリアの一つである。

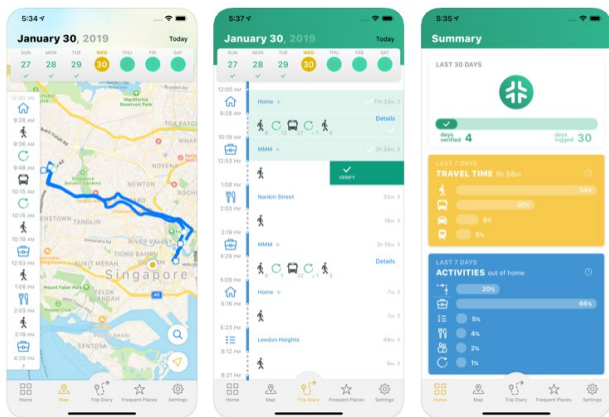


図-3.24 MMM社製のアプリ画面

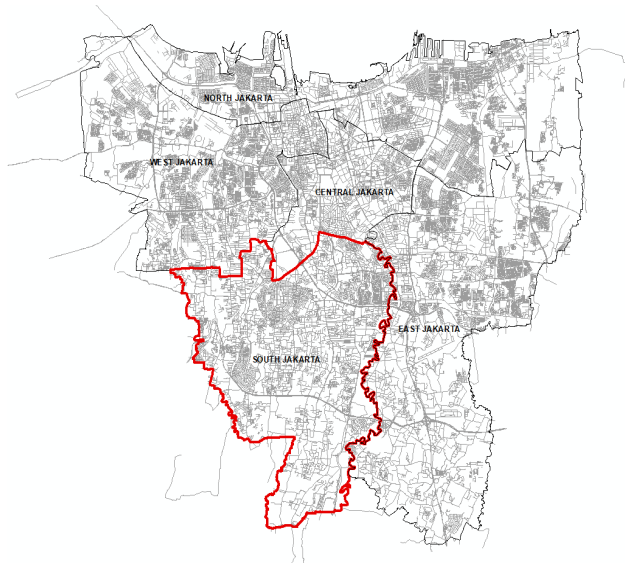


図-3.25 調査対象地域（南ジャカルタ）

本調査の一つ目の特徴は、図-3.26に示されるように、フィジカルな時空間上の生活・交通行動だけでなく、ICTを通じたバーチャルな活動参加（e活動と呼称する）を包括的に捉えている点にある。e活動を捉えるために、20分以上のすべての移動/活動に対してe活動実行の有無及びその内容について尋ねている。e活動の設問は、活動/トリップが完了し次第、被験者に回答を求める仕組みを採用している。

ICT利用に関して、実際の行動結果に合わせて個人毎にカスタマイズした選好意識調査（Pivoted SP調査）を実施した。3.2節に述べた調査のようにリアルタイムでの回答ができるアプリ開発はできなかったものの、時間制約や予算制約といった実際に意思決定をした際のすべての文脈要因すべてをSP調査に引き継ぐことができるcontext-aware SP調査の枠組みを用いた。具体的には、PP調査結果をもとにWeb上でSP調査票を作成し、後日、被験者に回答してもらう形をとった。SP調査の詳細は次節にて説明する。全体の調査の流れは図-3.27に示す通りである。

## (3) 基礎集計結果

表-3.14に社会経済属性の基本統計量を示す。表より、被験者の多くは40歳未満であり、年齢的に偏っていることが確認できる。これは、被験者をMSTPs利用者に限定したことにも起因していると考えられる。約70%の被験者が車を持っており、また、約30%がバイクを持っている。約半数が一人暮らし、残りは他の世帯構成員と一緒に住んでいることが確認できる。

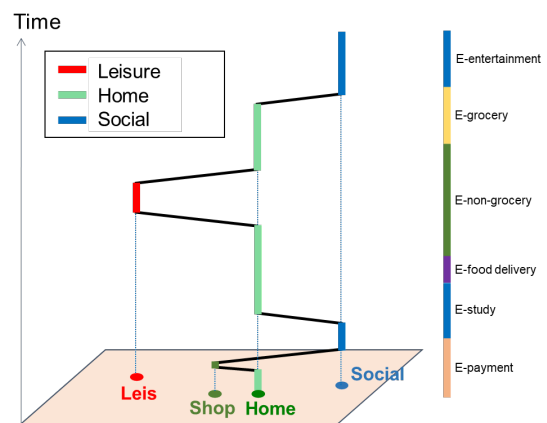


図-3.26 交通・生活行動とICT利用

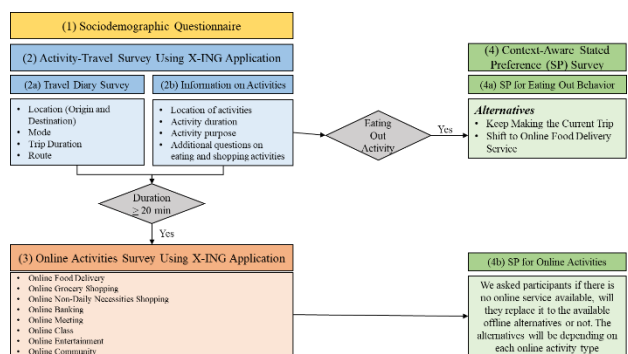


図-3.27 調査の流れ



表-3.14 社会経済属性の基本統計

Variable	Category	Total	Percentage
<b>Total number of respondents</b>		225	100.00%
Gender	Male	100	44.44%
	Female	125	55.56%
Age	18-22	21	9.33%
	23-27	128	56.89%
	28-32	43	19.11%
	33-37	29	12.89%
	38-42	4	1.78%
Marital	Single	152	67.56%
	Married	73	32.44%
Education	Junior High School	1	0.44%
	Senior High School	90	40.00%
	Diploma	14	6.22%
	Bachelor	110	48.89%
	Master and Doctor	10	4.44%
Job	Office Worker	205	91.11%
	Non-office Worker	20	8.89%
Provision Lunch by Workplace	Provided	42	18.67%
	Not Provided	183	81.33%
Car Ownership	Yes	158	70.22%
	No	67	29.78%
Motorbike Ownership	Yes	71	31.56%
	No	154	68.44%
Family Size	1	105	46.67%
	2	29	12.89%
	3	58	25.78%
	4	33	14.67%
	>5	10	4.44%
Average Income (in Mil. IDR per month)	Less than 1	8	3.56%
	1-3.99	58	25.78%
	4-7.99	118	52.44%
	8-9.99	31	13.78%
	More than 10	9	4.00%

表-3.15 交通手段分担率, 平均移動距離, 平均旅行時間

Travel mode	Average Travel	Average	Percentage
	Time (min)	Distance (km)	of trips (%)
Walk	95.82	2.65	17.83%
Car	47.18	19.24	29.96%
Motorbike	70.92	12.42	19.76%
Public Transit	77.59	15.16	10.46%
Ojek Online (MSTPs)	51.40	5.31	16.65%
Ride-Hailing/Taxi	36.83	15.34	2.35%
Others	230.31	25.39	2.99%
<b>Total (7112 trips)</b>	<b>319.59</b>	<b>19.18</b>	<b>100.00%</b>

表-3.16 オンライン活動の実態

Physical Activities	Virtual/Online Activities						Total	% of total
	Eat	Shoppin g	Worki ng	Educati on	Leisu re	Socia l		
Eating out	35	9	2	0	72	30	148	2.71
Shopping	14	18	3	2	23	10	70	1.28
Working	230	128	180	57	318	259	1172	21.46
Education	5	2	1	16	23	5	52	0.95
Leisure	2	3	0	1	26	4	36	0.66
Social	26	2	8	12	57	73	178	3.26
Home	371	152	202	109	868	448	2150	39.36
Others	12	7	3	4	62	138	226	4.14
Travel	251	133	104	67	446	429	1430	26.18
<b>Total</b>	<b>946</b>	<b>454</b>	<b>503</b>	<b>268</b>	<b>1895</b>	<b>1396</b>	<b>5462</b>	
<b>% of total</b>	<b>17.3</b>	<b>8.31</b>	<b>9.21</b>	<b>4.91</b>	<b>34.7</b>	<b>25.6</b>		




図-3.28 オンライン活動 vs 物理的活動

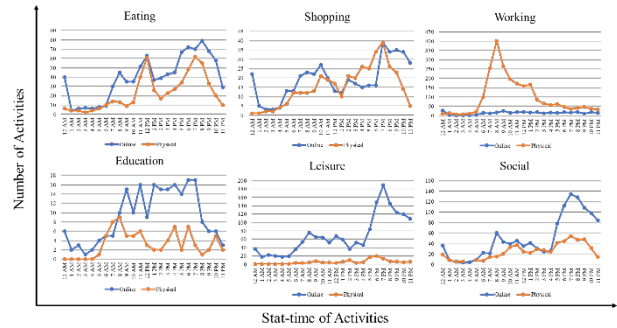


図-3.29 オンライン活動と物理的活動の実施時刻

表-3.15に交通手段分担率, 平均移動距離, 平均旅行時間を示す. 表より, 15%以上の移動がMSTPsによりなされていることが確認され, 配車サービスの交通システムへの影響は無視できないほど大きいことが示唆された.

表-3.16に調査より観測されたオンライン活動実施状況を示す. 表より, 自宅, 移動中, 職場の順でオンライン活動を実施していることが確認された.

図-3.28に活動タイプ別にオンライン活動と物理的活動の割合を示す. オンライン上の活動内容と物理的な移動を伴った活動内容は大きく異なると考えられるが, 回数ベースで見ると社会活動, レジャー活動, 教育活動だけでなく, 買い物, 食事においてもオンライン上で多くの活動が行われていることが確認された.

図-3.29にオンライン活動と物理的活動の実施時刻を整理する. 図より, オンライン上でのレジャー活動や社会活動は夕方~夜にかけて主に行われていること, 食事や買い物についてはオンライン活動と物理的活動で似通った分布となっていること等が確認できる.

#### (4) オンライン活動/物理的活動の選択に影響を及ぼす要因の分析

オンライン活動/物理的活動の選択に影響を及ぼす要因を把握するため, 被験者は, ある特定の活動ニーズを満たすために, オンラインでの活動または物理的な移動を伴う活動参加のいずれかを選択していると仮定し, この選択行動をパネル混合2項ロジットモデルによりモデル化する. オンライン活動/物理的活動の選択においては, 個人の好みが強ク反映されるものと考え, 非観測個人間異質性を捉えるためのランダム項を追加した.

表-3.17に推定結果を示す. 結果より, 上述した時間帯の影響に加え, (1) 家族人数が少ないほど, 世帯所得が低いほど, オンラインフードデリバリー(FD)

サービスを選択する傾向にあること、(2) 若い個人であればあるほど、既婚者であればあるほど、オンラインでの社会活動参加を選択する傾向にあること、などが確認された。また、非観測要因の影響を確認するために分散分解を行ったところ、個人内の異質性よりも個人間の異質性が卓越していることが確認された。以上のことから、オンライン/オフラインの選択は、文脈というよりは個人や世帯属性に影響を受けやすいことが示唆された。

#### (4) おわりに

本研究では、ジャカルタにおいてMSTPsが広く普及していることを鑑み、MSTPsを通じたFDサービスを含めたオンライン活動の影響を包括的に捉えるための調査を実施した。本章にて実施した予備的な分析から、MSTPsは、交通システムに対して無視できない影響を及ぼしているのみならず、人々の生活パターンに大きな影響を及ぼしていることが確認された。次節では、広く利用されているMSTPsを通じたオンラインFDサービスの利用に関する分析を実施する。

表-3.17 オンライン活動/物理的活動の2項ロジットモデル推定結果

Explanatory Variables	Eating (Online FD)		Shopping (online)		Leisure (online)		Social (online)	
	Est.	t-stat	Est.	t-stat	Est.	t-stat	Est.	t-stat
Constant	-1.90	-0.99	-2.26	-0.81	8.22	1.98 <sup>b</sup>	6.58	2.80 <sup>a</sup>
Gender (0=Male; 1=Female)	0.54	1.16	0.4	0.55	0.91	0.65	-0.57	-0.97
Age	0.12	1.53	0.11	0.83	-0.03	-0.17	-0.25	-2.33 <sup>t</sup>
Marital (0=Single; 1=Married)	0.25	0.35	-0.6	-0.55	0.51	0.35	1.5	1.66 <sup>c</sup>
Education (0= Not graduate; 1= Bachelor's degree or above)	0.2	0.37	-1.31	-1.77 <sup>c</sup>	-1.5	-1.17	-0.62	-1.01
Job (0=Non-office worker; 1=Office worker)	0.75	0.81	0.76	0.63	2.17	0.8	-0.71	-0.66
Car ownership (0= No; 1=Yes)	-0.22	-0.45	0.82	1.19	-0.39	-0.38	0.02	0.03
Motorbike ownership (0= No; 1=Yes)	0.65	1.18	-0.16	-0.25	-1.86	-1.33	-0.76	-0.95
Family size	-0.28	-1.73 <sup>c</sup>	-0.18	-0.78	-0.11	-0.33	0.12	0.79
Avg. income (in mil. IDR)	-0.13	-1.66 <sup>c</sup>	0.1	0.88	-0.19	-1.16	-0.07	-0.77
Time 2 (04:00:00-07:59:59)	0.07	0.18	-0.08	-0.13	-2.05	-2.51 <sup>b</sup>	-0.53	-1.46
Time 3 (08:00:00-11:59:59)	-0.002	-0.004	-1.14	-2.10 <sup>b</sup>	-1.09	-1.32	0.05	0.14
Time 4 (12:00:00-15:59:59)	-1.32	-3.93 <sup>a</sup>	-0.98	-1.74 <sup>c</sup>	-1.6	-2.27 <sup>b</sup>	-0.31	-1.00
Time 5 (16:00:00-19:59:59)	-1.15	-3.68 <sup>a</sup>	-1.33	-2.52 <sup>b</sup>	-2.11	-3.42 <sup>a</sup>	-0.72	-2.15 <sup>t</sup>
Time 6 (20:00:00-23:59:59)	-1.22	-3.69 <sup>a</sup>	-1.32	-2.48 <sup>b</sup>	-0.29	-0.37	-0.73	-2.11 <sup>t</sup>
Sigma (random parameter)	-2.31	-9.00 <sup>a</sup>	2.95	7.80 <sup>a</sup>	-3.95	-5.56 <sup>a</sup>	3.55	9.04 <sup>a</sup>
Number of individuals	177		137		121		163	
Sample size	1592		840		1864		2030	
LL (0)	-1103.49		-582.24		-1292.03		-1407.09	
LL (Final)	-714.88		-338.28		-358.92		-738.02	
AIC	1461.75		708.57		749.83		1508.04	
<b>Variance Explained by (%)</b>								
Observed Variables	24.10		7.85		24.18		22.68	
Unobserved inter-individual variables	46.91		66.87		62.59		61.30	
Other unobserved variables including intra-individual variations.	28.99		25.28		13.23		16.02	

### 3.7 マルチサービス交通プラットフォームが交通行動に与える影響に関する実証分析

#### (1) はじめに

GrabやGojekのようなマルチサービス交通プラットフォーム（以下MSTPs）によって提供されるオンラインフード配達サービスは、人々の外食行動や長期的な視線で見た飲食店の空間的分布を大きく変える可能性がある。本節は、前節にて紹介したインドネシアのジャカルタにて実施したスマートフォンを用いた移動調査と共に実施した、context-aware SP調査のデータを用いてオンラインフード配達サービスの利用に関する人々の選好へ与える要因を実証的に明らかにすることを試みる。本SP調査では、前述のジャカルタにおける移動調査（顕示選好、以下RP）データから外食トリップをランダムに抽出し、配達費用や配達時間、商品（フード）の代金、購入可能な商品の種類が設問ごとに変動する仮想状況下で、被験者のオンラインフード配達サービスへ移行する意思の有無を尋ねた。このSPとRPを組み合わせた手法によって、人々が持つ実際の時空間制約（例えば、13:00に再び仕事に戻る必要があるなど）の下で被験者の選好を尋ねることが可能となる。傾向スコアに基づくパネルロジットモデルを用いた本実証分析から、商品配達時間の節約価値は1時間当たり52,241 IDRと、既の実証されているインドネシアにおける平均的な移動時間節約価値（1時間当たり52,478 IDR）にほぼ等しいという結果を得た。これは、人々は現在地から遠い場所にあるオンラインフード配達サービスを利用しない傾向にあることを示し、郊外化が顧客の低下を招く可能性があるためMSTPsが加盟店の空間的な分布に対して与える影響は限定的であることを示唆する。

以下、(2)にてcontext-aware SP調査の概要を述べる。(3)にてモデルの概要と分析結果について考察する。(4)にて得られた知見をまとめる。

#### (2) Context-aware SP調査概要

本SP調査における属性とそれらの水準を表-3.18に示す。選択行動の現実性を高めるために、Pivoting型のSP調査を採用した。具体的には、具体的には、オンラインFDサービスの配達時間を生成するために、実際に外食時に費やした移動時間を使用した。また、配達費用は外食に伴う移動時の実際の距離に基づいて設定し、オンラインFDサービスのフード価格は、各被験者が実際にフードに対して支払った費用に基づいて設定した。仮想的なオンラインFDサービスにおいて購入可能なフードの種類は、次の2つの手順を通して生成した。まず、購入可能なフードの種類を生成した。その後、飲料、お菓子、ファストフード、インドネシア料理、洋食、東洋料理、バクソ（インドネシアの国民的料理）やヌードルの7つのフードの種類が格納されているリストから選択された番号に記載された数だけランダムに抽出した。なお、属性の組み合わせはランダムに生成した。

被験者の選択肢は、(1) 外食活動を継続する（行動変容しない）、(2) オンラインFDサービスへ移行する、の2つである。図-3.30に、SP設問のイメージを示す。

### (3) モデル概要と分析結果

ここでは、オンラインFDサービス利用における時間制約等の文脈要因とサービス水準の要因の影響を実証的に特定するためのモデルのフレームワークを説明する。上述したように、全ての文脈要因をSP属性として設定した上でSP調査を実施することはほとんど不可能に近い。前述したように、この問題に対する現実的な解決方法は、実際のRPの文脈を所与とした上でSP設問に回答する方法であり、本研究では、実際に外食を行った個人に対してcontext-aware SP調査を実施した。しかし、この調査手法では、外食へ行かなかった被験者を除外するため、自己選択バイアスが生じる恐れがある。本研究では、自己選択バイアスの問題を緩和するために、逆確率重みづけ (IPW) 法を使用した。具体的には、まず、選択肢が外食とオンラインFDサービスを含む各食事活動に対する外食活動の傾向スコアを推定する。そして、推定された傾向スコアの逆数として得られる重みを利用してオンラインFD利用に関する食事選択行動モデルを推定した。本手順によって、モデル推定に使用した標本（外食をした人々）が系統的に母集団と異なるという事実によって引き起こされるバイアスを（ある一定の仮定の下で）除去できる。

なお、オンラインFDサービスは既に市場にて供給されていることから、RPデータから類似のモデル構築が可能であるように思われるが、文脈的要因に対する感度を精度よく計測するためには上述のSPアプローチを採用することが重要と考える。具体的には、意思決定において文脈的要因が支配的であることは既知ではあるが、それらの多くは一般的には観測されない。これらの非観測要因の影響を把握するためには、同じRPの文脈の下で異なるオンラインFDサービスを被験者へ繰り返し提示し、どのように被験者が意思決定を変化させたかを観測することが望ましい。このような非観測文脈要因の影響を考慮したモデルを構築するには、パネルデータ分析におけるランダム効果に類似した、活動に特有の非観測文脈的要因を表す追加のランダム項を導入する必要がある。そこで以下の実証分析では、活動に特有の非観測文脈的要因を考慮したパネル混合ロジットモデルを採用した。

表-3.18にモデル推定に使用した説明変数とその基本統計量を示す。個人または家庭属性として、性別、年齢、配偶者の有無、被験者の平均月収、1か月間の平均家庭支出、被験者の職種、食事活動前後の滞在場所を示すダミー変数、社交活動を行う願望を表すダミー変数を用いる。最後の社交活動に対する願望を表す変数は、「もしも一緒に外食する誰かがいるならば、オンラインFDサービスよりもむしろ実際にレストランへ赴いて食事をしたい」という1~6の

リッカート尺度の態度質問から構成され、否定的な回答（強く反対、反対、やや反対）は0、肯定的な回答（やや賛成、賛成、強く賛成）は1としている。

前述した自己選択問題へ対処するために、まず、傾向スコアモデルを推定する。表-3.19に推定結果を示す。モデル推定結果より、若者、男性、配偶者有り、高年収の人々は、オンラインFDサービスよりもむしろ外食を選ぶ傾向にあることが示唆された。また、スケジュールに関連する要因については、仕事のスケジュールが固定されている人々と職場に残っている人々が外食を選択する傾向にあることが確認された。さらに、食事に社交目的を望む人々はオンラインFDサービスよりも外食を選ぶ傾向が示された。

表-3.20に食事選択行動モデルの推定結果を表す。IPW及び非観測文脈要因を表すランダム項導入の影響を調べるために、計4つのモデルを推定した。結果、IPW、非観測文脈要因の考慮双方ともに推定結果に大きな影響を及ぼすことが確認された。より具体的には、ランダム項の導入は、配達時間に関するパラメータの符号を変え、重みを考慮することは配達時間に関するパラメータの統計的有意性を変えた。後者は、母集団は外食活動よりも配達時間に対してより敏感であることを示唆している。外食をするということは、オンラインFDサービスを利用した場合と比較して人々の時間制約が少ない事を意味するため、本結果は論理的にも理解できる結果といえる。重みとランダム項を含むモデル推定結果より、配達時間とコストは有意であるが、食品の多様性、食品コスト、社交活動に対する願望は有意ではないことが示された。

表-3.18 SP属性及び水準

属性	水準	
オンラインFDサービスの配達時間 (移動調査から取得した実際の移動時間に基づく)	1. $0.4 \times$ 実際の移動時間	
	2. $0.7 \times$ 実際の移動時間	
	3. $1.0 \times$ 実際の移動時間	
	4. $1.3 \times$ 実際の移動時間	
	5. $1.6 \times$ 実際の移動時間	
オンラインFDサービスの配達費用 (移動調査から取得した実際の移動距離に基づく)	1. $0.4 \times 6,000 \text{ IDR} \times$ 実際の移動距離	
	2. $0.7 \times 6,000 \text{ IDR} \times$ 実際の移動距離	
	3. $1.0 \times 6,000 \text{ IDR} \times$ 実際の移動距離	
	4. $1.3 \times 6,000 \text{ IDR} \times$ 実際の移動距離	
	5. $1.6 \times 6,000 \text{ IDR} \times$ 実際の移動距離	
オンラインFDのフードの種類のみ組み合わせ	1. 1種類	
	2. 3種類	
	1. 飲料	3. 5種類
	2. お菓子	4. 7種類
	3. ファストフード	
	4. インドネシア料理	
	5. 洋食	
6. 東洋料理		
7. パクソやヌードル		
オンラインFDのフード価格 (移動調査から取得した実際のフード価格に基づく)	1. $0.8 \times$ 実際のフード価格	
	2. $0.9 \times$ 実際のフード価格	
	3. $1.0 \times$ 実際のフード価格	
	4. $1.1 \times$ 実際のフード価格	
	5. $1.2 \times$ 実際のフード価格	

あなたが実際に行った活動とその際の様々な制約を考慮した上で、もし次のようなオンラインFDサービスが利用可能だとしたら、外食からオンラインFDサービスへ移行しますか？

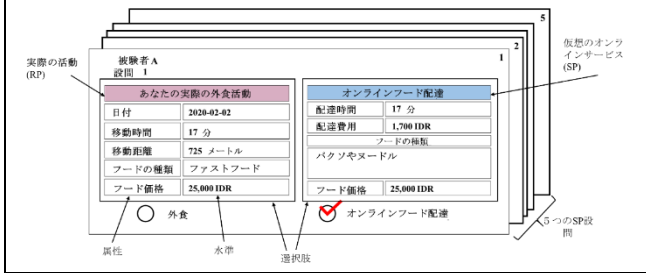


図-3.30 SP設問内容

-3.19 モデル推定に用いた説明変数の基本統計量

説明変数	最小値	平均	最大値
性別 (0 = 男性, 1 = 女性)	0	0.52	1.00
年齢	19	27	42
配偶者の有無 (0 = 独身, 1 = 配偶者有り)	0	0.32	1.00
被験者の平均月収 (単位: 百万 IDR)	0.50	6.13	20.00
1 か月間の平均家庭支出 (単位: 百万 IDR)	0.50	6.05	20.00
被験者の職種 (0 = 固定スケジュールの無い職種, 1 = 固定スケジュールの有る職種)	0	0.95	1.00
Home Before (1 = 直前の活動場所が自宅, 0 = それ以外)	0	0.14	1.00
Home After (1 = 次の活動場所が自宅, 0 = それ以外)	0	0.17	1.00
Work Before (1 = 直前の活動場所が職場, 0 = それ以外)	0	0.12	1.00
Work After (1 = 次の活動場所が職場, 0 = それ以外)	0	0.09	1.00
社交活動願望 (1 = 誰かと交流したい, 0 = それ以外)	0	0.45	1.00

表-3.20 傾向スコアモデル推定結果

説明変数	推定値	t 値	有意水準
定数項	-0.609	-1.08	
性別 (0 = 男性, 1 = 女性)	-0.219	-2.34	*
年齢	-0.081	-5.44	**
配偶者の有無 (0 = 独身, 1 = 配偶者有り)	0.497	3.59	**
被験者の平均月収 (単位: 百万 IDR)	0.041	2.67	**
1 か月間の平均家庭支出 (単位: 百万 IDR)	0.029	2.56	*
被験者の職種	2.150	5.64	**
Home Before (1 = 直前の活動場所が自宅, 0 = それ以外)	0.202	1.25	
Home After (1 = 次の活動場所が自宅, 0 = それ以外)	0.043	0.27	
Work Before (1 = 直前の活動場所が職場, 0 = それ以外)	0.605	3.19	**
Work After (1 = 次の活動場所が職場, 0 = それ以外)	-0.008	-0.04	
社交活動願望 (1 = 誰かと交流したい, 0 = それ以外)	0.351	3.93	**
AIC		2984.10	
初期対数尤度		-1577.60	
最終対数尤度		-1480.07	
サンプル数		2,276	

(\*\*)1%有意, (\*)5%有意

表-3.21 食事選択行動モデルの推定結果

	ランダム効果無し		ランダム効果有り	
	重み無し	重み有り	重み無し	重み有り
	推定値	t 値	推定値	t 値
定数項	-2.250	-15.20	-2.360	-14.00
社交活動願望 (1 = 誰かと交流したい, 0 = それ以外)	-0.207	-1.22	-0.287	-1.40
配達時間 (時間)	0.532	2.26	0.498	1.68
配達コスト (100,000 IDR)	-1.420	-3.98	-1.160	-2.92
フードの種類	0.436	12.80	0.461	11.40
フード価格 (100,000 IDR)	0.549	4.36	0.489	3.25
ランダム効果:			9.647	9.649
AIC	924.43		892.97	656.8
初期対数尤度	-774.93		-774.93	-774.93
最終対数尤度	-456.21		-440.48	-321.4
サンプル数			1,118	

オンラインFDサービスの待ち時間の時間価値は1時間当たり52,241 IDRであった。この値は、インドネシア国JABODETABEK都市交通政策統合プロジェクト2018年第2期によって公式に報告された1時間当たりの時間価値52,478 IDRとほぼ等しい。これは、外食とオンラインFDサービスの移動抵抗はほぼ同じであり、このことから、加盟飲食店の空間的な分布に対するオンラインFDの影響は、郊外へ移動すると顧客が減少することから限定的である可能性が示唆された。

(4) おわりに

本節では、context-aware SP調査データを用いてオンラインFDサービスが個人の食事活動に係る行動選択へ与える影響を定量的に示した。結果より、配達時間の長さは消費者にとっては待ち時間の長さを意味しており、MSTPsを通して注文したフードの待ち時間の時間価値は外食に伴う移動の時間価値とほぼ等しいことが示された。これは、加盟飲食店が郊外への移転を決定した際に、配達距離の増加と共に配達時間が増加するため、顧客が減少する可能性を示唆している。ただし、供給側の意思決定については分析できていない。このような新たな交通サービスが都市形態に及ぼす副次的な影響を把握することが交通マネジメントを考える上で重要との認識にたち、次節にて、加盟飲食店 (MSTPsの供給側) がユーザーの行動変化に対して反応するかについて追加的な検討を行う。

参考文献

- 1) 定金乾一郎, 小林勇介, 山中一平, 日下部貴彦, 朝倉康夫: プロブパーソン調査とSP調査による新交通手段の導入可能性の分析, 土木計画学研究・講演集, Vol. 42, CD-ROM, 2010.
- 2) Danaf, M., Atasoy, B., de Azevedo, C.L., Ding-Mastera, J., Abou-Zeid, M., Cox, M., Zhao, F., Ben-Akiva, M.: Context-aware stated preferences with smartphone-based travel surveys, Journal of Choice Modeling, Vol.31, pp35-50, 2019.
- 3) Train, K., Wilson, W.W.: Estimation on stated-preference

experiments constructed from revealed-preference choices, *Transportation Research Part B: Methodological*, Vol.42, No.3, pp.191-203, 2008.

- 4) Huynh, N.A., Chikaraishi, M., Fujiwara, A., Seya, H., Zhang, J.: Influences of tour complexity and trip flexibility on stated commuting mode: A case of mass rapid transit in Ho Chi Minh City, *Asian Transport Studies*, Vol.4, No.3, 536-549, 2017.
- 5) Azevedo, C.L., Seshadri, R., Gao, S., Atasoy, B., Akkinapally, A.P., Christofa, E., Zhao, F., Trancik, J., Ben-Akiva, M., 2018. Tripod: sustainable travel incentives with prediction, optimization, and personalization, in: *Proceedings of the Transportation Research Record 97th Annual Meeting*.
- 6) Pigou, A.C., 1920. *The economics of welfare*. Palgrave Macmillan.
- 7) Levinson, D., 2010. Equity effects of road pricing: A review. *Transp. Rev.* 30, 33–57.
- 8) Gallego, G., Van Ryzin, G., 1994. Optimal dynamic pricing of inventories with stochastic demand over finite horizons. *Manage. Sci.* 40, 999–1020.
- 9) Tan, Z., Yang, H., Guo, R.-Y., 2015. Dynamic congestion pricing with day-to-day flow evolution and user heterogeneity. *Transp. Res. Part C Emerg. Technol.* 61, 87–105.
- 10) Tiwari, G., Jain, D., 2012. Accessibility and safety indicators for all road users: case study Delhi BRT. *J. Transp. Geogr.* 22, 87–95.
- 11) Basu, A.J.R., Khatua, A., Ghosh, S., Jana, A., 2017. Harnessing Twitter Data for Analyzing Public Reactions to Transportation Policies: Evidences from the Odd-Even Policy in Delhi, India. *Proc. East. Asia Soc. Transp. Stud.*
- 12) Akamatsu, T., Sato, S., Nguyen, L.X., 2006. Tradable time-of-day bottleneck permits for morning commuters. *JSCE J. Infrastruct. Plan. Manag.* 62, 605–620.
- 13) Akamatsu, T., Wada, K., 2017. Tradable network permits: A new scheme for the most efficient use of network capacity. *Transp. Res. Part C Emerg. Technol.* 79, 178–195. <https://doi.org/https://doi.org/10.1016/j.trc.2017.03.009>
- 14) Lahlou, S., Wynter, L., 2017. A Nash equilibrium formulation of a tradable credits scheme for incentivizing transport choices: From next-generation public transport mode choice to HOT lanes. *Transp. Res. Part B Methodol.* 101, 185–212.
- 15) Yang, H., Wang, X., 2011. Managing network mobility with tradable credits. *Transp. Res. Part B Methodol.* 45, 580–594.
- 16) Hara, Y., 2018. Behavioral mechanism design for transportation services: Laboratory experiments and preference elicitation cost. *Transp. Res. Part B Methodol.* 115, 231–245.
- 17) Budish, E., 2012. Matching" versus" mechanism design. *ACM SIGecom Exch.* 11, 4–15.
- 18) Zhu, X., Wang, F., Chen, C., Reed, D.D., 2020. Personalized incentives for promoting sustainable travel behaviors. *Transp. Res. Part C Emerg. Technol.* 113, 314–331.

## 第4章 供給マネジメントへの拡張

### 4.1 はじめに

第2章、第3章において検討してきた需要マネジメントに加えて、供給側のマネジメントの必要性について検討を加えるため、以下の2つの分析を実施した。第一に、1次元都市モデルと確定的交通機関選択モデルを用いて、配車サービスと従前の公共交通機関の関係が協調もしくは競合となるような条件を明らかにする研究を実施した。提案モデル適用の結果、特に人口規模が小さい自動車依存型の都市においては、公共交通と配車サービスは競合関係になりやすいことが明らかとなった。このことは、需要側だけでなく、供給側のマネジメントも併せて実施する必要性を示唆する。第二に、オンラインフード配達サービスが施設分布に及ぼす影響を確認するため、サービス対応している施設とそうでない施設の空間分布の差異について考察を加えた。その結果、特に都心部と郊外部においてオンラインフード配達サービスに対応した店舗が増加していること、考えられる原因として、需要量に対する収益逡増のメカニズム、配達距離の増大に伴うサービスの質の低下が考えられる点を明らかとした。この結果は、配車サービスの利用は、需要側で閉じて決まるものではなく、ドライバー（供給）側、ひいては土地利用規制等にも影響を受けることを示唆しており、MSTPsの導入に伴う生活・交行動の変化を議論するためには、供給側及び土地利用の変化も含めた枠組みを採用する必要性が示された。

### 4.2 配車サービスと公共交通の競合可能性

#### (1) 背景・目的

近年、Uber や Lift などのライドヘイリングサービスやケータイアプリでタクシーの配車を行うインターネット配車サービスの普及が進展している。これらのサービスは路線バスなどの従来型の公共交通機関と比較して低コストで広域をカバーすることができるため、上述した移動難民の問題を解決できる可能性がある。日本においても Uber を過疎地の足として活用しようとする社会実験が進められる<sup>1</sup>など行政側の期待は大きいものの、過疎地におけるサービス展開は事業者の利益につながりにくいことから、他の過疎地域への展開が進んでいるとはいえない

い。事業利益の拡大を目的とするサービス事業者は、交通需要の大都市の都心部においてサービス展開を進めるが、例えば Uber などの普及が進むニューヨークにおいては、従来は地下鉄などの公共交通機関を用いていた人々が Uber に転換することによって市内の交通渋滞が深刻化するという問題が発生している。このように、行政側は配車サービスを従前の公共交通機関を補助する手段と位置づけて両者が協調することで地域の移動サービス水準が向上することを期待しているのに対して、実際は公共交通機関と配車サービスが競合し地域の移動サービス水準を悪化させるという状況が発生している。

このような状況をふまえて、本研究では、新しい交通サービスとして普及が進む配車サービスと従前の公共交通機関の関係が協調もしくは競合となるような条件を明らかにし、配車サービスの積極的な導入に対する補助金施策や、逆にエリア規制や料金規制などの規制による両者の関係性の変化について論じる。

自動車と公共交通の間の交通モード選択問題は、two mode problem と呼ばれ多くの研究が進められている<sup>1)4)</sup>。経済合理的な利用者の交通モード選択を考慮した上で公共交通と道路の容量を効率的に活用して社会全体のコストを最小化するためには、公共交通利用者と道路利用者に、各々の需要と供給に応じた適切な価格設定を行うことが必要である。しかし実際の都市では公共交通が有料であるのに対して道路利用は無料であることが多く、自動車を利用する人が過剰となって渋滞が発生し、都市の交通サービス水準の低下につながっている。この状況は、道路利用者に適切な課金が為されていないという意味から道路の underpricing 問題と呼ばれている。公共交通がある程度利用されている都市において道路が underpricing の場合に、渋滞を緩和のための道路拡張工事などを行って道路容量を拡張すると、従前は公共交通を利用していた利用者がさらに自動車利用に転換し、かえって交通サービス水準が低下することが多くの研究で示唆されている。

異常の two-mode problem を議論する多くの既往研究では単一出発地単一目的地モデル (single OD model) が使われており、都市の地理的条件はモデルから捨象されている。一方でLi et al. (2012)<sup>5)</sup>では、都

心から一定範囲のエリアで自動車利用者に課金を行うエリア課金制度を議論することを目的として1次元都市モデルを導入し、同一の道路を共有する自動車と路線バスの間での利用者のモード選択について議論している。自動車利用者への課金方法として、課金なし、エリア課金、距離課金、理想的課金の4種類を考えると同時に、バス事業者が地域の交通サービス向上を目的とする「公営企業」である場合と自社の収益向上を目指す「私営企業」である場合の2種類を考え、それぞれの場合における利用者の交通行動変容と地域の交通水準の変化について議論している。Two-mode problem に関する研究は多く行われているが、多くの研究において利用者が自動車と公共交通の2つのモードを自由に選択できることが前提となっている。現実には本章の冒頭で述べたように自動車を利用できない公共交通依存者が存在するが、従来の two-mode problem の枠組みにおいては公共交通依存者の存在は明示的には考慮されていない。問題の本質を簡潔に表現するため、本研究では、Li et al. (2012)<sup>9)</sup>と同様の1次元都市を考え、自動車を利用できる人々(自動車ユーザー)と利用できない人々(公共交通依存者)の交通機関選択行動について議論する。

## (2) モデル

本章では、紙面の都合上、想定する状況のみを簡潔に記述し、均衡解の照明や振る舞いの詳細等については省略し、結論のみを次章に述べる。詳細は、早川・力石 (2020)<sup>9)</sup>を参照されたい。

本研究では、図-4.1に示すような1次元都市における単一目的地モデルを考える。都市内の位置を座標  $x$  で定義し、都心  $x=0$  と都市域の境界  $x=B$  の2点に挟まれた区間  $x=[0,B]$  と都心  $x=0$  の相互間の移動需要について考える。地点  $x$  で発生する移動需要を  $\rho(x)$  とする。この移動需要のうち、自動車を利用できる利用者(自動車ユーザー)による移動需要を  $\rho_1(x)$ 、自動車を利用できない利用者(公共交通依存者)による移動需要を  $\rho_2(x)$  とする。ただし、 $\rho(x) = \rho_1(x) + \rho_2(x)$  であり、 $\rho_1(x)$  と  $\rho_2(x)$  は共に単調減少関数であるものとする。




図-4.1 1次元都市モデル

上述した1次元都市において、以下に示す自動車、公共交通および配車サービスの3つの交通モードを考える。

**自動車**：自動車で地点  $x$  から都心  $x=0$  まで移動する場合のコスト  $C^A(x, n_a)$  は以下で与えられるものとする。

$$C^A(x, n_a) = p^A(n_a) + \kappa^A x + \alpha t^A(x) \quad (4-1)$$

ここで、 $n_a$  は自動車の利用者数、 $p^A(n_a)$  は都心の駐車場料金、 $\kappa^A x$  は距離に比例する金銭コスト(ガソリン代など)、 $t^P(x)$  は自動車移動に関する所用時間を表すものとし、 $\alpha$  は時間コストを金銭コストに変換するための係数(時間価値)である。ただし、 $p^A(n_a) > 0$ ,  $\kappa^A \geq 0, t^A(x) \geq 0$ ,  $t^A(0) = 0$ ,  $\alpha > 0$  とする。

**公共交通**：公共交通で地点  $x$  から都心  $x=0$  まで移動する場合のコスト  $C^P(x)$  は以下で与えられるものとする。

$$C^P(x) = p^P + \kappa^P x + \alpha(t^P(x) + w^P(x)) \quad (4-2)$$

ここで、 $p^P$  は公共交通事業者によって設定される初乗り運賃、 $\kappa^P x$  は距離に比例する対距離運賃、 $t^P(x)$  は乗車時間である。公共交通の乗車時間  $t^P(x)$  および公共交通に乗り降りするための待ち時間  $w^P(x)$  は出発地  $x$  の関数で与えられるものとし、 $p^P > 0$ ,  $\kappa^P \geq 0, t^P(x) \geq 0$ ,  $t^P(0) = 0$ ,  $w^P(x) \geq 0$  とする。

**配車サービス**：配車サービスで地点  $x$  から都心  $x=0$  まで移動する場合のコスト  $C^E(x, n_e)$  は以下で与えられるものとする。

$$C^E(x, n_e) = p^E + \kappa^E x + \alpha(t^A(x) + w^E(n_e)) \quad (4-3)$$

ここで、 $p^E$  は初乗り運賃、 $\kappa^E x$  は距離に比例する対距離運賃、 $w^E(n_e)$  は配車サービスに乗り降りするための待ち時間であり、 $n_e$  は配車サービスを利用する人数である。また、 $t^A(x)$  は配車サービスで移動する際の所用時間であり、これは既に定義した自動車移動の場合の所用時間と等しい。ただし、 $p^E > 0$ ,  $\kappa^E \geq 0$ ,  $w^E(n_e) \geq 0$  とする。

**配車サービスから公共交通への乗り継ぎ**：自動車を利用せずに郊外部から都心へ移動する際には、郊外部では配車サービスを利用して途中で公共交通への乗り継ぐという手段が考えられる。地点  $x$  を出発地とし、途中の地点  $x_t < x$  で乗り継いで都心へ向かうときの移動コスト  $C^C(x, n_e, x_t)$  は、下式で示される。

$$C^C(x, n_e, x_t) = p^E + \kappa^E(x - x_t) + \alpha(t^A(x) - t^A(x_t) + w^E(n_e)) + p^P + \kappa^P x_t + \alpha(t^P(x_t) + w^P(x_t)) \quad (4-4)$$

上述の4つの移動モード(自動車、公共交通、配車サービス、乗り継ぎ)について、本研究では以下を仮定する。

### 仮定1：駐車場料金の単調増加性

駐車場料金  $p^A(n_a)$  は自動車の利用人数  $n_a$  に対して狭義単調増加である。

$$\frac{d}{dn_a} p^A(n_a) > 0 \quad (4-5)$$

**仮定 2：公共交通の待ち時間の単調増加性**

公共交通の待ち時間  $w^P(x)$  およびその導関数  $\frac{d}{dx} w^P(x)$  は、出発地点  $x$  に対して狭義単調増加である。

$$\frac{d}{dx} w^P(x) > 0, \forall x \in [0, B] \quad (4-6)$$

$$\frac{d^2}{dx^2} w^P(x) > 0, \forall x \in [0, B] \quad (4-7)$$

すなわち、出発地が都心から離れれば離れるほど公共交通の待ち時間は加速度的に増加し、都市境界  $x = B$  に近いような郊外部において公共交通を利用する場合には待ち時間が非常に長くなる。

**仮定 3：配車サービスの待ち時間の単調増加性**

配車サービスの待ち時間  $w^E(n_e)$  およびその導関数  $\frac{d}{dn_e} w^E(n_e)$  はサービス利用人数  $n_e$  に対して狭義単調増加である。

$$\frac{d}{dn_e} w^E(n_e) > 0 \quad (4-8)$$

$$\frac{d^2}{dn_e^2} w^E(n_e) > 0 \quad (4-9)$$

すなわち、配車サービスの利用者が増えれば配車待ち時間は加速度的に増加する。

**仮定 4：[対距離限界金銭コストの順位性]**

距離が増加することによる金銭コストの増加は配車サービス、公共交通、自動車の順に大きい。すなわち、

$$\kappa^E > \kappa^P > \kappa^A \quad (10)$$

**仮定 5：所用時間に関する順位性**

公共交通と自動車の所用時間差は、都心から離れれば離れるほど自動車有利、公共交通が不利となる。すなわち、

$$\frac{d}{dx} (t^P(x) - t^A(x)) > 0 \quad (11)$$

$$\frac{d^2}{dx^2} (t^P(x) - t^A(x)) > 0 \quad (12)$$

**仮定 6：内部均衡**

利用可能な4つの交通モード(自動車、公共交通、配車サービス、配車サービスと公共交通の乗り継ぎ)のうち、誰にも使われないモードは存在しない。すなわち、いずれのサービスも都市内の一定の条件を満たす利用者に利用される。

本研究で扱う交通モード選択モデルの枠組みを図-4.2に示す。まず、公共交通依存者の交通モード選択モデルについては、公共交通単独、配車サービス単独、および配車サービスと公共交通の乗り継ぎの3つのモードのうちの1つを選択する。乗り継ぎを選択した場合には、配車サービスから公共交通への乗り継ぎ地点も任意に選択できるものとする。自動車ユーザーについては、まず、自動車を利用し

て移動するか自動車を利用せずに移動するかを選択し、自動車を利用しない場合は、公共交通依存者と同様に交通モードを選択するものとする。なお、見通しを良くするため、交通モード選択モデルとして、確定的離散選択モデルを用いる。

以上の設定及び仮定のもとでは、図-4.3に例示するように、自宅の位置によって交通モードの選択が確定的に定まる。以上の条件のもと、(配車サービス導入前/導入後)×(中規模/大規模/小規模都市)の計6つのシナリオにおける解の振る舞いを検証し、配車サービスの導入が公共交通機関に及ぼす影響について考察した。

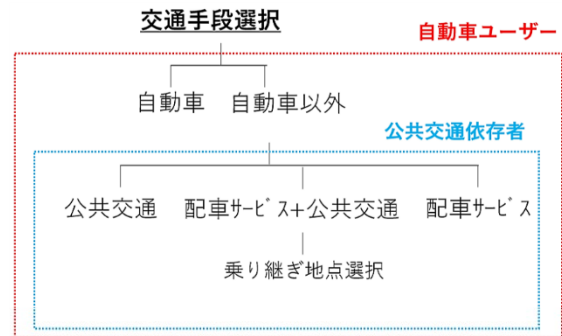


図-4.2 自動車ユーザーと公共交通依存者の交通モード選択モデル




図-4.3 公共交通依存者の交通モード選択例

**(3) モデルから得られる示唆**

モデル解析より得られる示唆は以下の通りである。

- **中規模都市**においては、配車サービスの導入は従前から自動車を利用している層に影響を及ぼさない。そのため、配車サービスと公共交通は、従来から公共交通を利用していた層を対象とした競争関係となり、配車サービスが利用されればされるほど公共交通の利用者が減る構図となる。公共交通の減収が許容できるのであれば中規模都市における配車サービスの導入は短期的には利用者にメリットをもたらすが、もし仮に減収により公共交通が維持できなければ長期的には地域の交通水準を悪化させる可能性がある。
- **大規模都市**においては、従前から自動車を利用している層も配車サービスの導入の影響を受ける。郊外の自動車利用者層の一部は配車サービスをフィーダーとして公共交通に乗り継ぐ



ような移動形態に転換する。この転換によって都心への自動車流入量が減少することから、他の自動車利用者の移動コストも低下し、多くの利用者にメリットをもたらすことができる。一方で、都心部においては中規模都市と同様に配車サービスと公共交通は競争関係となるため、バランスの良いサービス設計が望まれる。

- ▶ **小規模都市においては、わずかに残っていた都心部での公共交通利用が配車サービスに転換することにより、自動車ユーザーは全く公共交通を使わなくなる可能性がある。公共交通と配車サービスは自動車を利用できない公共交通依存者を対象とした競争関係となるが、利用者目線に立つと、郊外の公共交通依存者は配車サービスの導入によって移動コストを大きく下げることができるため、公共交通と配車サービスの適切な棲み分けを行うことが望ましい。**

以上の結果は、新たなモビリティ導入の是非は都市規模等の条件に依存することを示唆しており、様々なモビリティサービスが実装されつつある現在においては、需要だけでなく供給についても適切にマネジメントする必要性を示唆するものである。

### 4.3 配車サービスの都市施設分布への影響評価

#### (1) 背景・目的

GrabやGojekのようなマルチサービス交通プラットフォーム（以下MSTPs）は、移動の足としてだけでなく、オンラインフード配達サービスをはじめとした種々のデリバリーサービスを提供している。ここでは、こういったデリバリーサービスが土地利用に及ぼす影響について考察する。

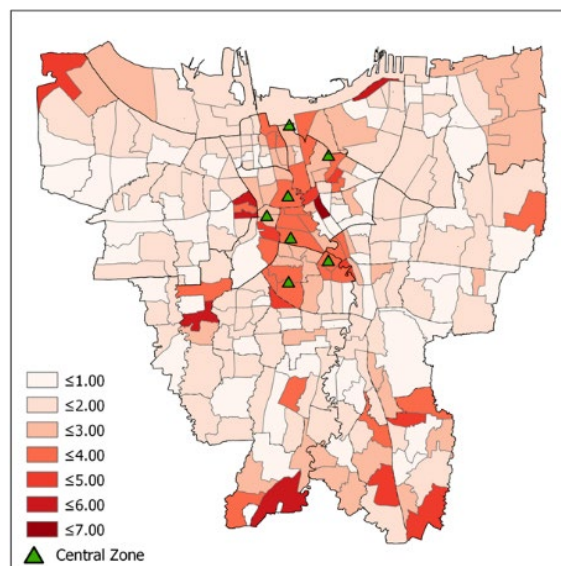
なお、紙面の都合上、主要な結果のみ要約する。詳細はSafira and Chikaraishi (2021)<sup>7)</sup>を参照されたい。

#### (2) 分析内容と得られた主な知見

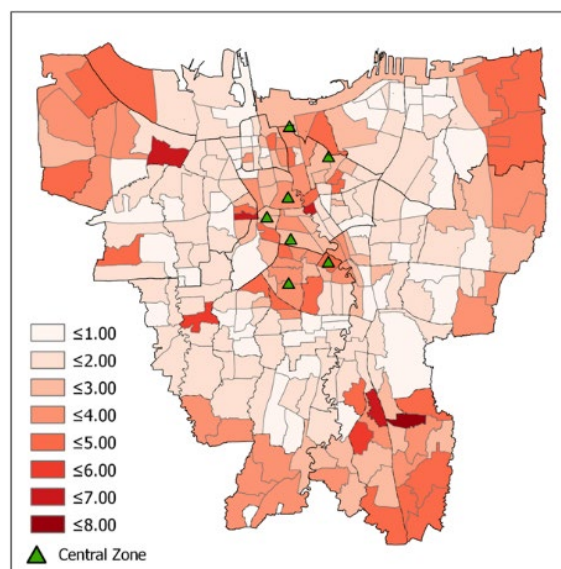
本研究では、Web crawlerを利用し、Google map上の飲食店情報を抽出した。次に、抽出した飲食店を表-4.1に示す種類に分類した。表より、既に9割以上の店舗がオンライン配達に対応していることが確認できる。次に、店舗種類間で立地特性に違いがあるかどうかを確認するために、店舗のエリア内の集積度及び店舗密度を計算した。集積度は、公共施設は集積の影響がないとの仮定のもと、「エリア内の公共施設の施設間平均距離／エリア内の店舗間平均距離」により算出した。

表-4.1 店舗の種類

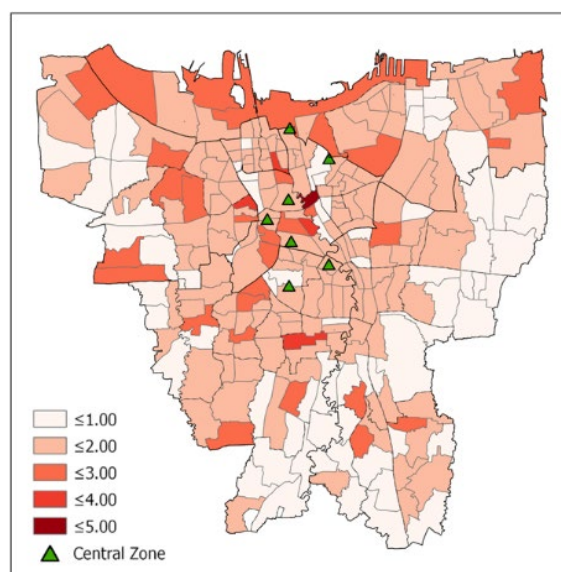
	店内での飲食	オンライン配達
Combination Food 店舗 (4,458 店舗)	可	可
Online Food 店舗 (3,718 店舗)	不可	可
Dine-in Food 店舗 (586 店舗)	可	不可



(a) Combination Food 店舗

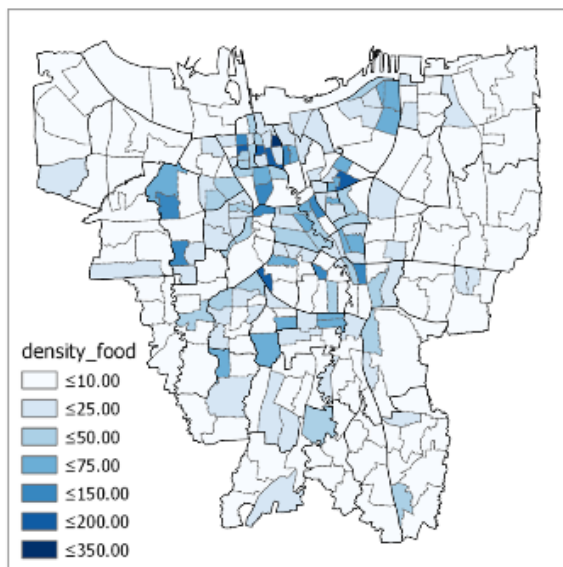


(b) Online Food 店舗




(c) Dine-in Food 店舗

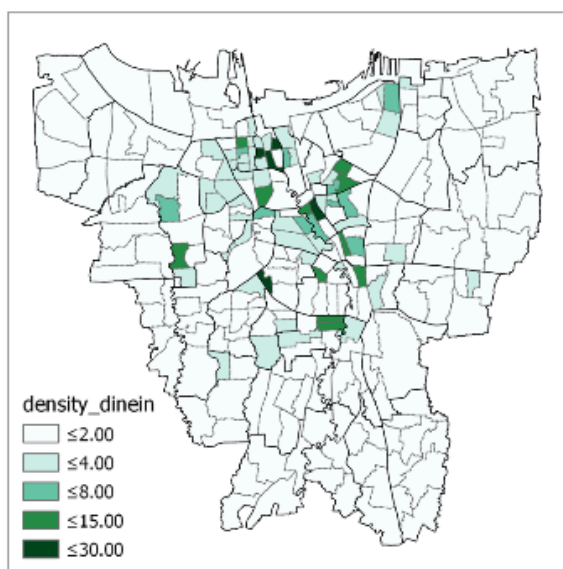
図-4.4 店舗の種類毎の集積指標



(d) Combination Food 店舗



(e) Online Food 店舗



(f) Dine-in Food 店舗

図-4.5 店舗の種類毎の店舗密度

図-4.4及び図-4.5に店舗の集積指標及び密度指標を示す。図より、オンライン配達を行っている店舗は、中心部だけでなく、郊外にも立地する傾向にあること、また、これらの店舗はエリア内で集積している（ある一部の場所に集まって立地している）ことが確認できる。また、土地利用が商業地として認定されている割合と集積指標/店舗密度の関係を図-4.6及び図-4.7に示す。図より、オンライン配達の店舗は、土地利用の用途に見合った形で施設が分布しないことが確認できる。このことは、より精緻な追加検証が必要である者の、配車サービスの導入がオンライン配達を通じて都市のかたちを変えうることを示唆するものといえる。




図-4.6 商業地の割合(%)と集積指標の関係




図-4.7 商業地の割合(%)と店舗密度の関係

#### 参考文献

- 1) Arnott, R. Yan, A.: The two-mode problem: Second-best pricing and capacity. Review of urban & regional development studies, 12(3):170-199, 2000.
- 2) d'Ouille, E.L., McDonald, J.F.: Optimal road capacity with a suboptimal congestion toll. Journal of Urban Economics, 28(1):34-49, 1990.
- 3) Kraus, M.: A new look at the two-mode problem. Journal of Urban Economics, 54(3):511-530, 2003.
- 4) Kraus, M.: Road pricing with optimal mass transit. Journal of Urban Economics, 72(2-3):81-86, 2012.
- 5) Li, Z.C., Lam, W.H.K., Wong, S.C.: Modeling intermodal equilibrium for bimodal transportation system design problems in a linear monocentric city. Transportation Research Part B: Methodological, 46(1):30-49, 2012.
- 6) 早川敬一郎, 力石真 (2020) 配車サービス導入評価のための確定的利用者均衡モデルの提案, 土木計画学研究・講演集, Vol. 62 (CD-ROM).
- 7) Safira, M., Chikaraishi, M.: Exploring the Impacts of Online Food Delivery Service on Facility Distribution: A Case of Jakarta, Indonesia, accepted for the Proceedings of 2021 EASTS conference.

# 第5章 災害時の交通マネジメントへの拡張

## 5.1 はじめに

本章では、交通需給マネジメントの災害時への拡張を念頭に、(1) 交通網の脆弱性評価、(2) 災害時における選好情報の抽出について検討を加える。全国69都市の交通網の脆弱性評価を行った結果、平成30年7月豪雨時に道路網が大きく被災した呉市は、全国の中でも極めて脆弱性の高い道路網を持つ都市であること等が明らかとなった。道路網の脆弱性を改善するには時間を要することから、交通マネジメントを通じて被災していない限られた道路網を賢く利用する交通マネジメント体系を構築することの重要性が改めて確認された。また、災害時の交通マネジメントに資する情報を得るための選好情報の抽出手法として、災害時の出発時刻選択を尋ねる新たな表明選好調査の設計手法を提案した。

なお、紙面の都合上、背景と主要な結果のみ要約する。分析手法等の詳細については、Santos et al. (2021)<sup>1)</sup>及びMatsumoto et al. (2021)<sup>2)</sup>を参照されたい。

## 5.2 道路交通ネットワークの脆弱性評価

### (1) 背景・目的

本章では、日本69都市（図-5.1）の交通ネットワークの脆弱性を評価する実証分析を行った。具体的には、1)交通ネットワークの効率性の評価、2)ランダムアタック（道路をランダムに切断）及びターゲットアタック（重要な道路から順に切断）が生じた場合のネットワーク頑健性（network-robustness）の評価、3) ネットワークの効率性、頑健性と、各自治体の税收状況などを含んだ都市レベルでの変数との関係性の分析を行った。

### (2) 分析方法の概要

図-5.2に本研究において実施した分析の概要を示す。まず、対象とする69都市各々に対し、道路網の効率性を計算した。効率性指標は、「各ノードペア結ぶ最短経路の旅行時間の逆数の平均値」として計算した。逆数をとっているのは、接続のないネットワーク間においても計算を可能にするためである。なお、本指標は、「各ノードペアのユークリッド距離の逆数の平均値」を用いて基準化している。

次に、ランダムに5%、10%、15%の道路リンクを削

除（ランダムアタックと呼称）した際の効率性、媒介中心性の高い道路から5%、10%、15%の道路リンクを削除（ターゲットアタックと呼称）した際の効率性を計算し、道路リンクを削除する前の効率性からの減少割合を脆弱性指標とした。最後に、脆弱性指標と都市の道路網特性、規模、交通システム属性、財政状態などとの関係性を解析し、どのような都市において特に脆弱性が高くなるのか、実証的に確認した。

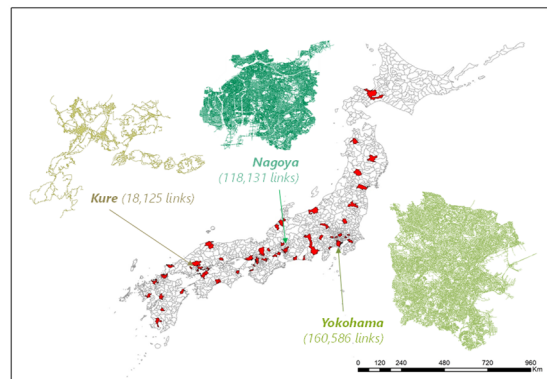


図-5.1 対象とする69都市

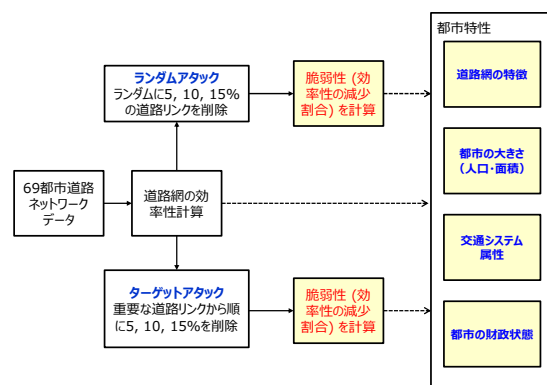


図-5.2 分析の概要

### (3) 主要な知見

効率性及び脆弱性指標の基本統計を表-5.1に、ランダムアタックに対する脆弱性を図-5.3に、ターゲットアタックに対する脆弱性を図-5.4に示す。これらの図より、特にランダムアタックに対しては市の面積に対する道路総延長が短い都市ほど脆弱である


こと、また、本研究で対象としている呉市はいずれの攻撃に対しても脆弱な道路網を有することが確認された。

また、都市属性との関係性を統計的に確認したところ、主に以下の知見を得た。


- **ネットワーク構造:** 道路ネットワークの接続性が良い(ノード数に比してリンク数が多い)ほど、ランダム攻撃、ターゲット攻撃に強い。
- **インフラ投資:** インフラ投資水準が高い大都市ほどランダム攻撃に強い。
- **空間集積:** a) 都市集積のため、大都市ほどターゲット攻撃に弱い, b) 一方、小都市ほど都市集積が生じておらず、ターゲット攻撃に強い。
- **交通手段分担:** a) 自動車依存都市の方がランダム攻撃に弱く、ターゲット攻撃に強い, b) 一方、鉄道依存都市の方がターゲット攻撃に弱い。

脆弱性の改善は長期の時間を要することを踏まえると、災害時の交通需要マネジメントの必要性は、呉をはじめとした特に脆弱性の高い都市において必要と考えられる。本節にて行った分析は、このような交通需要マネジメントの事前検討のための基礎資料として利用することができる。

5%の道路をランダムに切断した場合



10%の道路をランダムに切断した場合



15%の道路をランダムに切断した場合

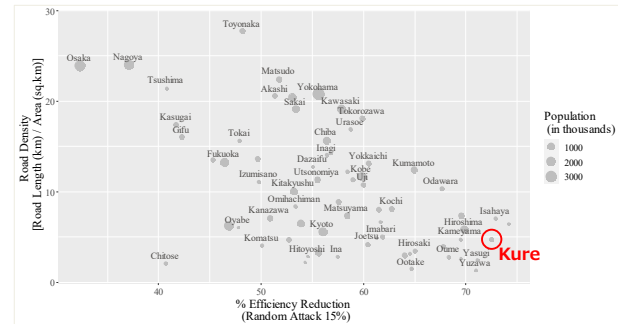



図-5.3 ランダム攻撃に対する脆弱性


表5-1 効率性及び脆弱性指標の基本統計

Vulnerability indicator	Mean (std deviation)	Maximum (city)	Minimum (city)
Efficiency	0.21(0.036)	0.28 (Oyabe)	0.12 (Uji)
Robustness (Random attack)			
Percent reduction at 5%	20.54 (4.20)	33.06 (Yuzawa)	8.52 (Osaka)
Percent reduction at 10%	39.52 (8.22)	63.84 (Kainan)	19.34 (Nagoya)
Percent reduction at 15%	57.23 (9.09)	74.14 (Kainan)	32.31 (Osaka)
Robustness (Targeted attack)			
Percent reduction at 5%	40.96 (6.28)	57.08 (Kobe)	26.20 (Oyabe)
Percent reduction at 10%	61.62 (7.21)	82.41 (Kobe)	42.36 (Oyabe)
Percent reduction at 15%	76.77 (7.43)	88.96 (Kobe)	54.72 (Oyabe)

媒介中心性の高い順に5%の道路を切断した場合



媒介中心性の高い順に10%の道路を切断した場合



媒介中心性の高い順に15%の道路を切断した場合




図-5.4 ターゲット攻撃に対する脆弱性

### 5.3 災害時の交通行動を捉えるためのSP調査設計

#### (1) 背景・目的

災害はいつどこで起こるか、どれほどの被害が発生するか予測が困難であるため、災害時に発生する渋滞への対応としてはソフト面の対策が必要不可欠である。以下ではその中でも、交通需要マネジメント(TDM)施策の1つである時差出勤に着目し、時差出勤の効果を検討する上で必要となる、災害時における従業員の出発時刻選好を把握するためのSP調査設計を提案する。これらのSP調査手法は、例え

ばPP-SP調査の一部に組み込むことが可能であるとともに、「incenTrip」等の日常的に使われている行動変容アプリに実装することができれば、災害時に簡便に人々の選好情報を得ることができ、災害時の交通需要マネジメントを大きく改善できる可能性がある。

提案するSP調査の設計では、回答者それぞれの実際の通勤にかかる旅行時間に基づきSP調査設問を生成する。つまり、回答者それぞれの旅行時間によって、SP調査で提示する状況を変え、より回答者が仮想の状況を自分の状況としてイメージしやすくする。3章において議論したように、このような設問生成の方法は、Pivoted SPなどと呼ばれ、コンピュータを利用した調査手法の普及とともに広く実施されるようになってきている。

## (2) SP調査の設計

SP調査では、災害時を想定し、回答者に仮想的な始業時刻を提示した上で望ましい出発時刻を(A)、(B)の二択から選択してもらう形式とした。選択肢(A)、(B)にはそれぞれ5つの旅行時間と始業時刻からの早遅着を提示し、等確率で5パターンの旅行時間が発生するという設定にする。ここで旅行時間を5パターン提示したのは、この調査では災害時を仮定しているため、正確な旅行時間を把握するのが難しいという災害時特有の情報不確実性を反映している。また、選択肢(A)は遅着無し、選択肢(B)は5回中1,2回遅着する可能性があるように旅行時間を設定する。回答者の実際の通勤にかかる旅行時間が30分だった場合のSP設問の例を図-5.5に示す。

作成するSP調査票には8つの属性を使用した。ただし、利用する8つの属性は直接交通サービス水準を示唆するものではない。具体的には、8つの属性を用いて被験者が理解できる交通サービス水準を生成するステップが必要になる。また、各属性に対して割り当てた水準については、実験計画法ではなく、ランダムに割り当てる形式をとった。ランダムに割り当てることにより、交互作用項の推定が可能になる。表-5.2に使用した属性及び水準を示す。

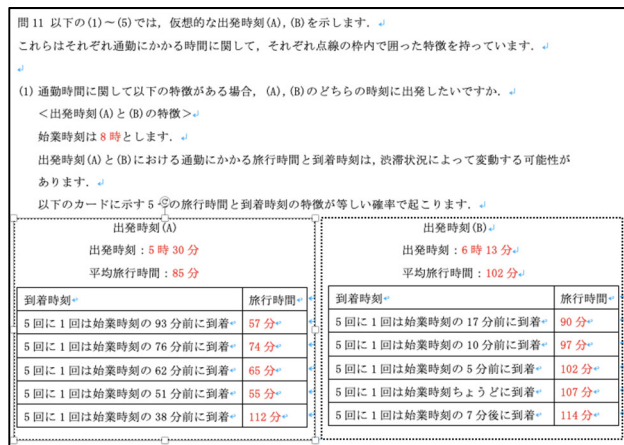


図-5.5 SP設問画面例

第一手順として、回答者の旅行時間 $X$  (図7.3-1の場合は30分)に基づいて平均旅行時間分布 $f(t)$  (図7.5-1の中では黒の折れ線グラフ)を決定していく。ここで、平均旅行時間分布とは、普段の通勤には平均 $X$ 時間かかる回答者が、災害時において時刻 $t$ に出発した場合、通勤にどれほどの時間がかかるかを示している。つまり、 $f(t)$ は災害状況下での仮想的な渋滞パターンを表している。この渋滞パターンは、パッシブデータの観測値から決めればよい。 $f(t)$ の決定方法は、まず平均旅行時間が最も大きくなる(渋滞のピークに通勤することになる)出発時刻 $P$ と、時刻 $P$ に出発した場合の平均旅行時間 $T$ を乱数 $p_2, p_3$ を用いて決定する(式(5-1),(5-2))。次に、旅行時間ピーク時刻 $P$ への交通集中の程度を表す、 $f(t)$ の傾き $\alpha$ を乱数 $p_4$ を用いて算出する(式(5-3))。最後に、今回のSP調査票は災害時を仮定して設計するため、通勤にかかる旅行時間が回答者の通常時の旅行時間 $X$ より小さくならないように $f(t) \geq X$ の制限をかける。以上の手順によって $f(t)$ (式(5-4))を決定する。

$$\text{旅行時間ピーク時刻 } P = p_2 \quad (5-1)$$

$$\text{ピーク時刻の旅行時間 } T = X \times p_3 \quad (5-2)$$

$$\text{旅行時間の傾き} = T \times p_4 \quad (5-3)$$

平均旅行時間分布

$$f(t) = \begin{cases} T & (P = t \text{ の場合}) \\ T - \alpha(P - t) & (t < P \text{ の場合}) \\ T - \alpha(t - P) & (t > P \text{ の場合}) \end{cases} \quad (5-4)$$

SP調査票を設計する第二手順として、始業時刻(図-5.6中の黒の実線)及び選択肢(A)、(B)それぞれについて5つの到着時刻(図-5.6中の5本の赤と青の点線)を決定する。まず、始業時刻 $S$ を乱数 $p_1$ を用いて決定する(式(5-5))。ここで、始業時刻をランダムに決定している理由は、このSP調査の結果から得られた従業員の出発時刻選択に関する結果を、始業時刻選択モデルと関連づけられるようにするためである。次に、選択肢(A)、(B)各々に遅着回避度合い $\beta_A, \beta_B$ (式(5-6),(5-7))を設定し、「始業時刻 $S$ -遅着回避度合い $\beta_A, \beta_B$ 」を平均とするロジスティック分布に従う形で、選択肢(A)の到着時刻( $arrA10, arrA30, arrA50, arrA70, arrA90$ ), (B)の到着時刻( $arrB10, arrB30, arrB50, arrB70, arrB90$ )を決定した。ただし、選択肢(A)は遅着がないように、選択肢(B)は5回中1,2回遅着する可能性があるように遅着度合い $\beta_A, \beta_B$ を設定する。

$$\text{始業時刻 } S = p_1 \quad (5-5)$$

選択肢(A)の遅着回避度合い

$$\beta_A = \text{ロジスティック分布 } N(0, \sigma_A^2) \text{ の } p_7 \text{ パーセンタイル値} \quad (5-6)$$

選択肢(B)の遅着回避度合い

$$\beta_B = \text{ロジスティック分布 } N(0, \sigma_B^2) \text{ の } p_8 \text{ パーセンタイル値} \quad (5-7)$$

$$\text{ここで, } \sigma_A = T \times p_5 \div 10 \quad (5-8)$$

$$\sigma_B = T \times p_6 \div 10 \quad (5-9)$$

### 選択肢 (A) の到着時刻

arrA10 = ロジスティック分布  $N(S - \beta_A, \sigma_A \times (f(t_{ont} - \beta_A)/T))$  の 10 パーセンタイル値

arrA30 = ロジスティック分布  $N(S - \beta_A, \sigma_A \times (f(t_{ont} - \beta_A)/T))$  の 30 パーセンタイル値

arrA50 = ロジスティック分布  $N(S - \beta_A, \sigma_A \times (f(t_{ont} - \beta_A)/T))$  の 50 パーセンタイル値

arrA70 = ロジスティック分布  $N(S - \beta_A, \sigma_A \times (f(t_{ont} - \beta_A)/T))$  の 70 パーセンタイル値

arrA90 = ロジスティック分布  $N(S - \beta_A, \sigma_A \times (f(t_{ont} - \beta_A)/T))$  の 90 パーセンタイル値

### 選択肢 (B) の到着時刻

arrB10 = ロジスティック分布  $N(S - \beta_B, \sigma_B \times (f(t_{ont} - \beta_B)/T))$  の 10 パーセンタイル値

arrB30 = ロジスティック分布  $N(S - \beta_B, \sigma_B \times (f(t_{ont} - \beta_B)/T))$  の 30 パーセンタイル値

arrB50 = ロジスティック分布  $N(S - \beta_B, \sigma_B \times (f(t_{ont} - \beta_B)/T))$  の 50 パーセンタイル値

arrB70 = ロジスティック分布  $N(S - \beta_B, \sigma_B \times (f(t_{ont} - \beta_B)/T))$  の 70 パーセンタイル値

arrB90 = ロジスティック分布  $N(S - \beta_B, \sigma_B \times (f(t_{ont} - \beta_B)/T))$  の 90 パーセンタイル値

ここで,  $t_{ont}$  は平均旅行時間で移動した場合に時刻  $S$  に到着するような出発時刻である.

$$t_{ont} = \begin{cases} S - T & (P + T = S \text{ の場合}) \\ \frac{S - T + \alpha P}{1 + \alpha} & (P + T > S \text{ の場合}) \\ \frac{S - T - \alpha P}{1 - \alpha} & (P + T < S \text{ の場合}) \end{cases}$$

SP 調査票を設計する最後の手順として, 平均旅行時間分布  $f(t)$  と選択肢 (A), (B) それぞれの到着時刻の中央値 ( $arrA50$  と  $arrB50$ ) を用いて, 選択肢

(A), (B) それぞれの出発時刻 (図-5.6 中の赤と青の実線) を決定する.  $f(t)$  は時刻  $t$  に出発した時の平均旅行時間を表すため, 平均旅行時間  $f(t)$  で移動すれば  $arrA50$  と  $arrB50$  に到着するような時刻  $t$  を出発時刻  $t_A, t_B$  に決定する. つまり,  $f(t_A) = arrA50 - t_A$ ,  $f(t_B) = arrB50 - t_B$  を満たすような  $t_A, t_B$  (式 (5-10), (5-11)) を求める.

### (3) まとめ

本節では, 災害時における出発時刻に関する選好情報を得るための SP 調査手法を提案した. 提案した SP 調査手法の特徴を以下にまとめる. まず, 始業時刻をランダムに設定することで, (1) SP 調査結果から出発時刻選択モデルを導出した際に, 出発時刻選択モデルと企業の始業時刻選択モデルを関連づけることができる点, (2) 選択肢としての出発時刻の幅が広がり, 機会費用を考慮したモデルを作成しやすくなる点, が挙げられる. 次に, 回答者の実際の通勤時間に合わせて, それぞれの災害時における平均旅行時間分布を仮定しているため, どの時刻に出発しても通常時より旅行時間が短くならないように設定することで, “災害時” であるという設定を SP 調査票の中に確実に取り入れることができる. また, 平均旅行時間分布は災害時の渋滞のパターンを意味しており, これを仮定した上で出発時刻を決定することは, より現実の選択状況に沿っていると考えられる. 最後に, 属性の水準をパッシブデータから生成することにより, 政策決定者側の追加の負担なく出発時刻選好を抽出するよう調査の枠組みを拡張することも可能である.

表-5.2 SP 調査設計に使用した属性

属性	水準
$p_1$	[6 時, 7 時, 8 時, 9 時, 10 時] からランダムに挿入
$p_2$	[7 時, 8 時, 9 時] からランダムに挿入
$p_3$	[2, 3, 4] からランダムに挿入
$p_4$	[0.1, 0.2] からランダムに挿入
$p_5$	[1, 2, 3] からランダムに挿入
$p_6$	[1, 2, 3] からランダムに挿入
$p_7$	一様分布 (最小 0.9, 最大 0.99) からランダムに挿入
$p_8$	一様分布 (最小 0.6, 最大 0.89) からランダムに挿入

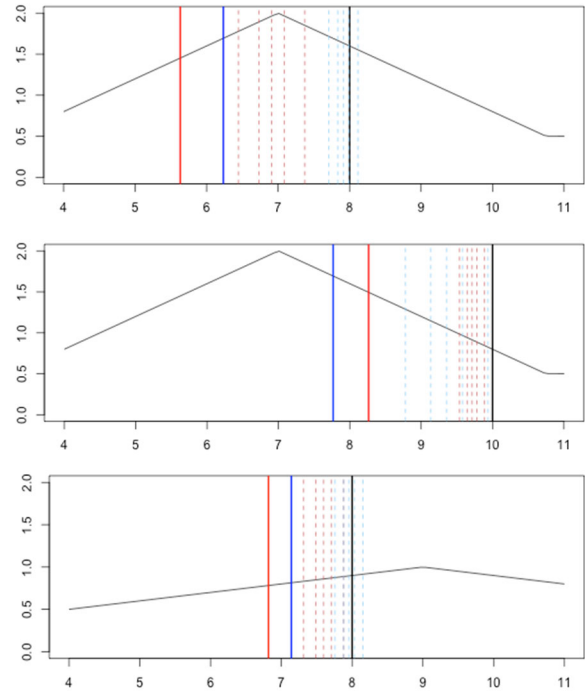


図-5.6 生成される旅行時間分布と選択肢 A の出発時刻 (赤実線) / 到着時刻 (赤点線) 及び選択肢 B の出発時刻 (青実線) / 到着時刻 (青点線) の例 (横軸: 時刻; 縦軸: 旅行時間)

### 参考文献

- 1) Santos, J.R., Safitri, N.D., Safira, M., Varghese, V., Chikaraishi, M. (2021) Road Network Vulnerability and City-level Characteristics: A Nationwide Comparative Analysis of Japanese Cities, Environment and Planning B: Urban Analytics and City Science (Accepted).
- 2) Matsumoto, N., Chikaraishi, M., Fujiwara, A., Kanda, Y. (2021) Exploring firms' adaptive behavior on work start time during disaster with the consideration of traffic congestion and temporal agglomeration economies, Paper presented at the 100th Annual Meeting of the Transportation Research Board, January 25-29, online conference.

# 第6章 総合的な交通需給マネジメントに向けたICTアーキテクチャの検討

## 6.1 ICTが交通行動に及ぼす影響の包括的レビュー

情報通信技術 (ICT) の利用は、人々の生活に不可欠なものとなると共に、活動参加や交通行動の様々な要因と複雑な相互作用を有する。しかしながら、ICTシステムの急速な進展や上記の関係性の複雑化により、全体的なアーキテクチャ (設計)、サブコンポーネント (要素)、およびそれらの相互作用の理解が低下してきている。そこで以下では、(1) サブコンポーネント間の相互関係を特定し、ICTと交通行動の関係の背後にあるアーキテクチャを確立すること、(2) ICTの交通政策に対する影響を最大化するためのロードマップを策定する概念モデルを提案することを目的とした包括的なレビューを実施した文献は、関連するデータベースでのキーワード検索、そして既往のレビュー研究を通して選定した。186件の実証研究のレビューにより、調査方法、ICTデバイス、サービス、アプリケーションの不均一性、そしてICTと交通行動に関連する要因との直接的な関係性、および政策立案に関連する排出量、土地利用、混雑などの他のパラメーターへの高次または間接的な影響が示された。また、ICTによる交通行動のアーキテクチャは4つの異なるタイプの類型に分類できることが示された。そして、それぞれのタイプの分析におけるメリット、デメリット、および課題を示した。さらに、1) ICTシステム、2) 交通行動要因、3) 高次の影響等の想定される関係性を考慮した概念モデルを構築した。紙面の都合上、以下ではレビューの結果得られた示唆のみを要約する。

### (1) ICT-交通システムアーキテクチャの分類

既存研究には4つのタイプのICT-交通行動システムが存在することが示された (図-6.1)。多くの既往研究は、第一タイプのシステムに分類される。このタイプでは、ICTと交通行動間の単体の効果に着目した分析がなされる。一方、構造的でより包括的な視点を持つ研究は、第二タイプのシステムに含まれる。第二タイプに属する研究は第一タイプに比べて少ないものの、双方共に着目するICTデバイスやサービスのタイプは類似しており、多変量化した点が

主要な違いになる。第三タイプおよび第四タイプのICT-交通行動のアーキテクチャでは、ICTが交通の供給システムに及ぼす影響が考慮される。第四タイプは、ICTベースの取引プラットフォームによる交通行動要因と供給側の要因が双方に直接リンクしているという点で、第三タイプと異なっている。

特に重要な点は、前章までにおいて繰り返し見てきたように、第四タイプのサービスの実装が進みつつあるにも関わらず、第四タイプのもので実現する交通システムの性質について、我々は極めて限定的な理解しかできていない点にある。このため、次節において述べるように、影響の不確実性に配慮しつつ逐次モニタリングしながら、政策介入を適応的に変更していかざるを得ないのが現状であるように思われる。次節にて、そのような検討を進める上で補助線となり得る概念モデルを整理する。

### (2) 概念モデルの構築

図-6.2に第四タイプのアーキテクチャ導入時の影響評価を支援する概念モデルを示す。提案する概念モデルから得られる主な示唆は以下の通りである。

- 1) ICTと交通行動要因との関係を分析した既存研究の多くは、情報提供にのみに着目するものが多いが、ICTデバイスやサービスは、より多くの応用が可能である。例えば、これらのICTツールを積極的に活用することで、移動等に関する個人の正確な嗜好を導き出すことが可能となる。例えば Hara (2018)<sup>1)</sup>は、取引コスト、認知的負担、認知的バイアス、誤認識など観測されていないユーザーの様々な制約が、交通や活動目的の潜在的な需要の不表示につながると主張している。これらに対して、適切なICT-交通システムの導入によって選好の誘発コストを削減し、対処することができる。
- 2) ユーザーの移動の選好理解は拡大可能であり、ICTは交通システムの性能を考慮しつつ、利用者中心の交通サービスを提供することに貢献することが可能である。例えば、Copenhagenで構築されたツールであるMinRejseplanでは、様々な交通手段の統合を実施している<sup>2)</sup>。VilniusやRio de Janeiro, Jakarta等でも同様のツールが存在し<sup>3)</sup>、交

通手段に関連する選択に加え、駐車管理システムやTBPなど他の交通サービスにも展開可能となっている。利用者へのアラート機能や、ルート選択に関する助言、過去や将来の交通行動の保存機能、およびポイントや報酬機能などのICTベースのプラットフォーム<sup>3)-5)</sup>も、上記のツールと統合することが可能である。

- 3) 最後に、ICTと交通行動の動的な関係性に対応し、  
 a) ICT利用の影響を考慮した異なる交通サービスの需供均衡および b) ICTの長期的・高次的な影響の二つの要素をモデル化できる方法論的フレームワークを構築した事例はほとんどなく、公共政策としてのアプリ実装においては、これらの長期的な影響に配慮した枠組みを採用することが今後の重要な課題となろう。

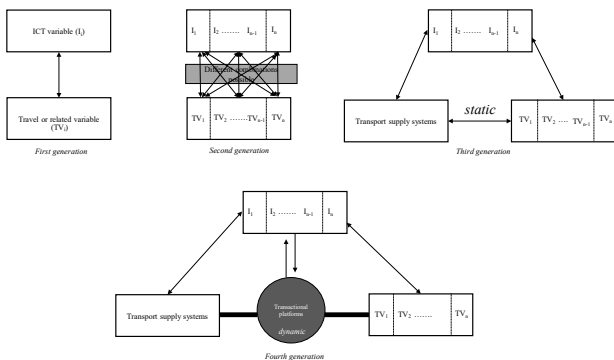


図-6.1 ICT-交通システムアーキテクチャの進展

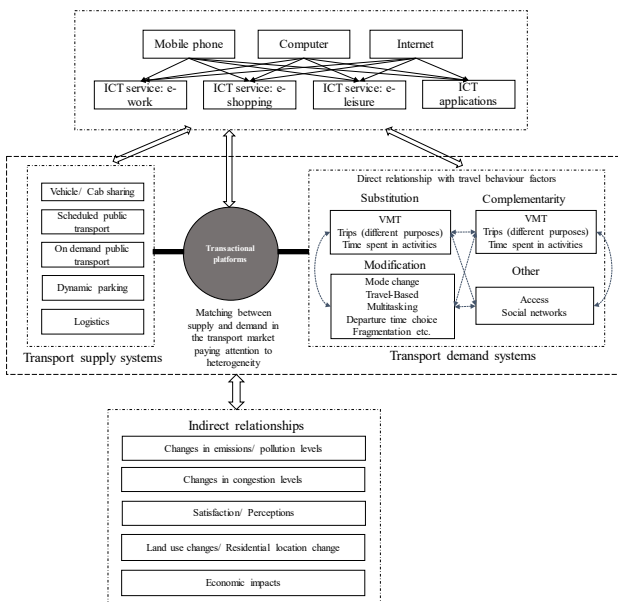


図-6.2 第四タイプのアーキテクチャ導入時の影響評価を支援する概念モデル

### (3) まとめ

本論文の主要な成果は以下の二点である。第一に、実証研究の広範なレビューにより、既存研究におけるデータ収集手法、調査対象範囲、ICTデバイス、サービス、分析対象のアプリケーション、および分析された関係性等を明確にした。第二に、レビューを

通して、分析構造、サブコンポーネント、及びそれらの既存の関係性と想定される関係性など、ICTと交通行動の関係性のアーキテクチャの理解に繋げた。これらを踏まえ、次節では、次世代型ICTアーキテクチャに求められる要件を整理する。

## 6.2 次世代型ICTアーキテクチャの試案

### (1) 背景・目的

本章では、データの観測からアウトプットまでのICTアーキテクチャを整理し、次世代の交通需給マネジメント実施に向けた今後の方向性を試行的に議論する。当初、細部まで作り上げたICTアーキテクチャを整理することを念頭に置き研究を進めていたが、後述するように、技術の進展に大きな不確実性を孕むこと等から、ICTアーキテクチャそのものを提示するのではなく、その設計に当たって留意すべき点を整理する方針をとった。

3章において議論したように、ICTの発展に伴い、様々な交通マネジメントツールの開発が進んでいる。需要側のマネジメントについては、混雑課金をはじめとした価格ベースの戦略から、通行権取引をはじめとした数量ベースの戦略が提案されてきた。一方、これらの戦略の限界は、そのシステムの外側に存在する要因を反映することが難しい点が挙げられる。これは、最適化問題の外部にある要因を考慮できないというだけでなく、本来は新たな技術革新に応じて更新しうるはずの介入形態を硬直化させてしまう可能性があるという点においても問題がある。従って実装の文脈においては、betterなマッチングを目指すアルゴリズムや、一定のルールに基づき生成されたインセンティブ付与によるマネジメントといった、一定のフレキシビリティを担保した形での社会実装が望ましいものと考えられる。

加えて、環境意識が高い個人、健康志向型の個人といったように、選好が個人間で異なるため、行動変容を促すための介入も個人に対してカスタマイズすることが、社会余剰最大化の観点からは望ましい可能性がある。このような個人にカスタマイズされた介入戦略の事例として、例えばMITの研究チームが開発しているTripodや、メリーランド大学の研究チームが開発しているincenTripがある。本研究においても、これらの既存のアプリ開発と同様の視点に立ち、個人にカスタマイズしたインセンティブの付与、レコメンデーションの提示を試行的に実施し、その効果を確かめた。得られた重要な知見の一つに、我々がモデルを用いて再構成する利用者の選好は、本人の実際の選好と一定の剥離があるため、トライ&エラーを繰り返し、介入の強度を適応的に変えるフレームワークを採用する必要があるという点である。エビデンスに基づく政策決定の観点からは、強い仮定のもとで理論的に導出された最適混雑課金を実装するよりも、最小限の仮定の中で識別可能な因果推論に基づきながら介入の強度を調整するスキームを採用する方針が望ましいように思われる。



本章では、このような近年のエビデンスに基づく政策決定に関する研究成果を鑑み、フレキシブルにルールが変更できることを前提としたICTアーキテクチャについて考察し、その社会実装に向けた今後の方向性を議論する。以下では、まず、ICTアーキテクチャの入力情報となるデータについて整理する。次に、それらのデータを利用するためのICTアーキテクチャ像を議論する。その後、継続して生じる技術革新を踏まえると、常に未完成であることを念頭に置いた社会実装が望ましいことを指摘する。次に、そのような状況の中でできる限り効率的により良いICTアーキテクチャを構築していくための方法として、Manski (2013)<sup>7)</sup>が提示する不確実性に配慮したランダム化比較実験の枠組みが有用であることを主張する。

## (2) 入力データ

本節では、ICTアーキテクチャの入力データである、供給側データ、需要側データ（パッシブデータ、表明選好データ）の双方を整理する。なお、具体的に整備すべきデータは、都市の状況や制度に依存するため、ここでは大きな方針の提示のみを試みる

**供給側のデータ**：前節のレビューを踏まえると、ICT時代の交通マネジメントは、供給側のマネジメントと需要側のマネジメント双方を含む概念として捉えるべきといえる。また、需要側の交通をマネジメントする場合においても、基本的には供給量を踏まえて介入の強度を決定する必要があることから、供給側のデータ整理は必須といえる。ここで、供給側のデータ整理とは、道路ネットワークや鉄道ネットワークといったインフラ、鉄道やバスのタイムテーブルといった既存交通サービスに関するデータだけでなく、配車サービスやマイクロモビリティの運用データも含まれる。例えば諸外国の幾つかの都市では、配車サービスやマイクロモビリティサービスを供給する主体にデータ提供を義務付けているケースが散見される。とりわけ交通サービスが異なる主体で運行されている状況下においては、新たな交通サービスの導入が交通システム全体のパフォーマンスを低下させる恐れがあることから、collectiveに機能する交通システムを作り上げるためには、データ提供を義務付けるような方策が望ましいと考えられる。

**パッシブデータ**：近年、GPSデータ、公共交通ICカードデータ、携帯電話位置情報、感知器データ、ETCデータなど、様々なパッシブデータの利活用が進んでいる。これらのデータはいずれも効率的な交通マネジメントを実施するための有用な情報を含んでいる。特に、日々の交通マネジメントを実施する上では、例えば1時間後どの程度の個人がある道路区間を利用するか、といった短期予測が重要な場面が多く(図9-2)、2章にて導入した機械学習手法とパッシブデータの相性は極めて高い。また、パッシブデータは利用者に負担をかけることなく取得できるデータであ

ることから、可能な限りパッシブデータに基づき介入の強度を決める枠組みを採用することが望ましい。なお、種々のパッシブデータの特徴やその利活用方法については、既に多くの既往研究があることから、ここでは省略する。

**選好情報の抽出**：3章において議論したように、パッシブデータは、過去になされた行動履歴情報を含む一方、将来の選好情報を含むデータではない。従って、パッシブデータをベースにマネジメントの意思決定を行うためには、短期の将来予測／推論が必要になる。このような将来時点の推論は、朝の交通渋滞をはじめとした繰り返し生じる事象については精度よく実行できると予想される。一方、交通事故や災害、イベントに伴う渋滞など、繰り返しのない、非日常な事象に伴い発生する交通状態を予測することは極めて困難である。例えば本研究プロジェクトにおいて扱ってきた平成30年7月豪雨後の交通マネジメントにおいては、パッシブデータによる短期予測を試みてきたが、一般的な短期予測に比べて精度が劣ることを確認している。このような状況を鑑みると、パッシブデータだけに頼るのではなく、一部の重要な情報については、ユーザーから選好を表明してもらう形でデータを収集することで将来時点の推論の精度を飛躍的に高めることができる可能性がある。実際、UberやLyftなどの配車サービスにおいては、利用者が行きたい場所をアプリ上で情報提供する。これは、ユーザーに将来時点の選好を直接表明してもらっていることに該当し、このような将来時点の選好を把握する仕組みを積極的に導入しておくことが、例えば災害時の交通マネジメントにおいて役立つと思われる。より具体的には、昨年度に提示した災害時の出発時刻選択に関するSP調査を簡便に実施可能なチャンネルを持っていれば、より効率的に始業時刻及び出発時刻の分散が図れた可能性がある。平時だけではなく、災害時においても有用な交通マネジメントの枠組みを構築する上で、選好情報を抽出するコンポーネントをICTアーキテクチャの一部に位置付けることは極めて重要と考える。

## (3) ICTアーキテクチャ像

以上の議論を踏まえ、ユーザーの観点から整理したICTアーキテクチャ概念図を図6.1-3に示す。提示した概念図はあくまでも一例に過ぎないが、いくつかの要点を以下に列挙する。

- 第2章において議論したように、パッシブデータは、適切なアルゴリズム／モデル（例えば短期予測）によって処理されて初めて交通マネジメント上有用な情報に変換される。実装されるべきアルゴリズム／モデルはデータやマネジメント対象によって異なるが、インプットデータを入力すれば介入が完了するアルゴリズム／モデルが実装されていることが求められる。
- 第3章、第5章において議論したように、災害やイベントといった非日常の交通マネジメントに向

け、選好情報を尋ねることのできる、双方向に情報やデータをやり取りするICTアーキテクチャを採用することが望ましい。

- 前節においてレビューしたように、介入の結果交通状態が変わり、それがまたユーザーの行動変容を促しうるため、情報提供した結果生じる行動変容を逐次観測するためのコンポーネントがICTアーキテクチャに組み込まれていることが望ましい。
- ICTアーキテクチャの完成形は存在しないことを念頭に、各要素を個別に開発でき、自由に組み合わせることのできるアーキテクチャを採用することが望ましい。

### (5) 社会実装に向けた今後の方向性

上に概説したようなICTアーキテクチャを社会実装するにおいて、アジャイル型の開発が可能であることが極めて重要なように思われる。本章を、この点の議論で締めくくる。

常に更新を続けるICTアーキテクチャを採用する必要性は、主に以下の2点にあると考える。

- **不確実性**：より良い技術開発が行われる、需要が大幅に減少／増加する、都市構造に大きな変化が生じるなど、将来時点の状況が完全には見通せない状況で社会実装を進めざるを得ない。また、例えばアプリを通じてインセンティブを付与する場合、アプリの画面設計により反応が異なることが予想されるが、決定すべき事項が多数にわたるため、適切な設計指針を絞り込むことが難しく、実行する介入の効果についても不確実性が伴う。
- **価値判断の変化**：災害時や感染症を抑制することに主眼を置くべき時期においては、異なる価値判断基準で交通マネジメントを行う必要が出てくる。

不確実性に対しては、Manski (2013)が主張する時間的・空間的な適応的分散処置を実施する形でICTアーキテクチャの社会実装を進めていくことが望ましいように思われる。この処置では、適応的に介入内容を変えて効果を評価し続け、介入内容を徐々に更新する戦略をとる。より具体的には、過去に採用してきたICTアーキテクチャがもたらす行動変容を逐次評価し次の設計に活かしていく、エリアで異なるICTアーキテクチャを採用し、その効果を検証し、次のICTアーキテクチャの設計につなげる戦略である。これに加え、価値判断の変化にも対応しようとする、フレキシブルに設定を変更可能なICTアーキテクチャを初期の段階で導入する必要性は極めて高いと思われる。すなわち、初期の導入時に気を付けるべきことは、どのような短期予測の手法が実装されているか、どのような選好情報の抽出手段が実装されているか、といったようなコンポーネント選択よりもむしろ、新しいコンポーネントを容易に追加できるような制度設計になっているか、各コンポ

ネントの専門家が容易に参画できるような体制になっているか、といった構築しようとする仕組みのガバナンスに関わる種々の事項について時間をかけて検討することが重要と思われる。

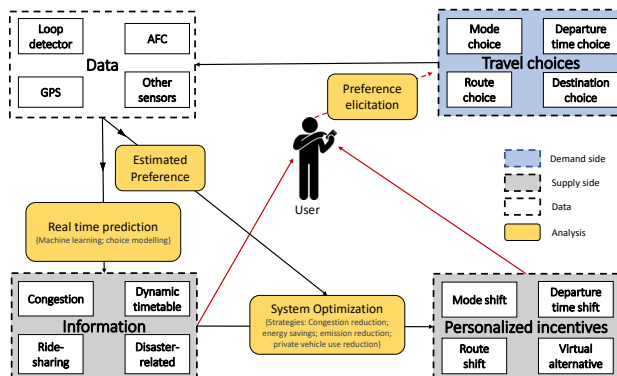


図6.1-3 ICT-交通システムアーキテクチャの進展

### 参考文献

- 1) Hara, Y., 2018. Behavioral mechanism design for transportation services: Laboratory experiments and preference elicitation cost. *Transp. Res. Part B Methodol.* 115, 231–245.
- 2) ITS World Congress, 2018. The story of ‘MinRejseplan’ – a major step towards MaaS [WWW Document]. URL <http://asp.vejtid.dk/Artikler/2018/ITSWC/9073.pdf> (accessed 2.19.19).
- 3) Jordans, F., 2019. Berlin to get single travel app for public, private services. *AP news*.
- 4) Brazil, W., Caulfield, B., 2013. Does green make a difference: The potential role of smartphone technology in transport behaviour. *Transp. Res. Part C Emerg. Technol.* 37, 93–101.
- 5) Dastjerdi, A.M., Kaplan, S., e Silva, J. de A., Nielsen, O.A., Pereira, F.C., 2019. Factors driving the adoption of mobility-management travel app: a bayesian structural equation modelling analysis, in: *The Transportation Research Board (TRB) 98th Annual Meeting*.
- 6) Yujuico, E., 2015. Considerations in the diffusion of a public traffic app for Metro Manila. *J. Transp. Geogr.* 42, 48–56.
- 7) Manski, C.F. 2013. *Public Policy in an Uncertain World*, Harvard University Press.

## 第7章 研究成果のまとめと今後の課題

本研究では、100年に1度の変革期を迎えている交通システムの総合的な需給マネジメント手法構築を目指し、以下の3テーマについて研究を行った。

- (1) AI技術に基づく短期予測手法の開発
- (2) 新たな観測・介入ツールの開発と交通需要マネジメントへの適用
- (3) 総合的な交通需給マネジメントに向けた次世代のICTアーキテクチャの検討

平成30年7月豪雨災害を受け、研究対象を一部拡大しながら研究を進めたが、当初計画していた研究目的は十分に達成できたと考える。

(1) AI技術に基づく短期予測手法の開発(2章)では、交通分野における機械学習手法の短期予測適用例を網羅的にレビューし、学術雑誌にて公表されている結果を整理したデータベースを作成、メタ解析を実施し、対象とする交通事象や使用するデータと解析手法の選択の関係を定量的に明らかにした。レビュー成果をもとに、車両感知器データやETC2.0データ、モバイル空間統計、公共交通ICカードデータ等のパッシブデータを利用し、平時及び災害時の交通状態/OD交通量の短期予測を行う一連の手法を整理し、その精度を実証的に検証した。交通理論が提供する交通現象の明快な解釈と、機械学習手法が提供する予測精度の大幅な向上の双方のメリットを享受するハイブリッド型の短期予測手法についても併せて開発した。特に、(1) 災害時においても転移学習等を用いることで精度の高い短期予測が可能であること、(2) 一方、予測精度の高いモデルが、必ずしも現象のメカニズムをより良く模倣するわけではないこと、(3) 交通理論と整合的な機械学習手法の構築も可能であること、を示した点に学術的・実務的な価値があると考えている。

(2) 新たな観測・介入ツールの開発と交通需要マネジメントへの適用(3章)では、RP行動結果をもとにリアルタイムで政策に対する選好情報を尋ねるreal-time context-aware 表明選好(SP)調査手法を開発し、混雑課金の影響評価に適用した。また、個々人の時間価値の異質性を手掛かりに、パーソナライズされたインセンティブを生成するためのアルゴリズムを開発し、生成したインセンティブが付与される

状況下及びレコメンデーション情報提供下における交通行動を観測・評価する介入実験を行った。さらに、GojekやGrabといったマルチサービス交通プラットフォーム(MSTPs)が生活・交通行動に及ぼす影響を確認することを目的に、インドネシア・ジャカルタ市を対象としたプローブパーソン(PP)-表明選好(SP)調査を設計・開発し、特にオンラインフード配達サービスの影響評価に焦点を当てた分析を実施した。特に、(1) SP調査への回答タイミングがモデル同定に大きな影響を及ぼすこと、(2) パーソナライズされたインセンティブの付与の効果は、事前の予測と大きく乖離する恐れがあること、(3) MSTPsの導入は、交通行動のみならず、フードデリバリーサービスの利用等、生活行動全般に無視できない影響を及ぼしていること等が明らかとなった。

(3) 総合的な交通需給マネジメントに向けた次世代のICTアーキテクチャの検討(4, 5, 6章)では、上述の(1)、(2)で開発した要素技術を前提に、総合的な交通需給マネジメントを実装するためのICTアーキテクチャを検討した。具体的には、まず、「供給マネジメントへの拡張」、「災害時の交通マネジメントへの拡張」について追加の検討を行い、MSTPs等の出現によって交通供給主体間で競合する可能性があること、災害時における円滑な交通マネジメントのためには、交通マネジメント主体(公的主体)が需給マネジメントツールに積極的に関与できる体系が望ましいこと等の示唆を得た。次に、ICTが交通行動に及ぼす影響の包括的レビューを行い、次世代型ICTアーキテクチャについて検討した。(1) 新たな交通サービスの導入が交通システム全体のパフォーマンスを低下させる恐れがあることから、collectiveに機能する交通システムを作り上げるためには、データ提供を義務付けるような方策が望ましいこと、(2) パッシブデータは利用者に負担をかけることなく取得できるデータであることから、可能な限りパッシブデータに基づき介入の強度を決める枠組みを採用することが望ましいこと、(3) ただし、災害等のノンリカレントな交通事象の予測においては、リアルタイムに選好情報を抽出する機能が備わったICTアーキテクチャであることが望ましいこと、(4) 技術革新や価値判断の変化といった不確実性に対応するために、時間的・空間的な適応的分散処置を実施する

形でICTアーキテクチャの社会実装を進めていくことが望ましいこと、等を整理した。

上記の検討を総合的に踏まえると、特に災害が頻発する我が国においては、公的主体が積極的にアプリ開発に関与する意義は極めて大きいと考える。我が国では個々の企業がMaaSの枠組みのもと種々のアプリ開発を進めているが、コペンハーゲンなど、公的主体が主導して交通需給マネジメントのためのアプリを開発するケースが散見されるようになってきており、我が国においても同様の取り組みを積極的に進めるべき時期に来ているように思われる。こういった取り組みを災害時の交通需給マネジメント体系の中に位置付けることで、災害時の行動モニタリングにもなり、次の災害の備えを検討するための貴重な情報源にもなり得る。また、開発したプラットフォームを各企業に開放しAPI連携できるようにすれば、多様な交通サービス供給主体が協調する交通市場の実現にもつながる。その際、詳細を作り込んだICTアーキテクチャを設計・実装するのではなく、様々なコンポーネントを自由に追加／削除できるような柔軟なICTアーキテクチャを採用することも重要になってくるものと考えられる。

(2021年6月30日受理)

道路政策の質の向上に資する技術研究開発 成果報告レポート No.30-1

A1 技術に基づく短期交通予測手法と総合的な交通需要マネジメントの研究開発

2021.6